

VILNIAUS UNIVERSITETAS

Giedrius
STABINGIS

Statistiniai sprendimai erdvinei informacijai skaitmeniniuose vaizduose

DAKTARO DISERTACIJA

Gamtos mokslai,
informatika N 009

VILNIUS 2019

Disertacija rengta 2014–2018 metais Vilniaus universitete.

Mokslinis vadovas:

prof. habil. dr. Gintautas Dzemyda (Vilniaus universitetas, gamtos mokslai, informatika – N 009).

Mokslinis konsultantas:

prof. dr. Kęstutis Dučinskas (Klaipėdos universitetas, gamtos mokslai, informatika – N 009)

PADEKA

Nuoširdžiai dėkoju moksliniam vadovui prof. habil. dr. Gintautui Dzemydai už vertingas mokslines konsultacijas, nuoseklų vadovavimą, neišsenkančią kantrybę ir pagalbą rengiant šią disertaciją.

Dėkoju moksliniam konsultantui prof. dr. (HP) Kęstučiui Dučinskui už vertingus patarimus, pastabas ir diskusijas.

Esu dėkingas disertacijos recenzentams prof. habil. dr. Romualdai Baušiui ir doc. dr. Povilui Treigiui, atidžiai perskaičiusiems disertaciją ir pateikusiems vertingų patarimų bei kritinių pastabų.

Dėkoju visiems disertacijos metu vykdytų tyrimų bendraautoriams, ypač dr. Jolitai Bernatavičienei ir prof. habil. dr. Alvydui Paunksniui, už suteiktas žinias ir bendradarbiavimą.

Nuoširdžiai dėkoju savo artimiesiems už paramą, moralinį palaikymą, kantrybę ir supratingumą.

Taip pat dėkoju visiems, kurie tiesiogiai ar netiesiogiai prisidėjo prie šio darbo.

Giedrius Stabingis

SANTRAUKA

Dėl vaizdų gavimo techninės įrangos pažangos vaizdų gavimas, kaupimas ir analizė tampa neatsiejama biomedicinos, inžinerijos, gamtos ir socialinių mokslų dalimi. Vaizdų analizė jau yra svarbus informacijos gavimo įrankis, o tobulėjant vaizdų gavimo įrangai atsiranda naujų iššūkių ir galimybių. Skaitmeniniai vaizdai darosi reikšminga sprendimų priėmimo dalimi.

Šiame darbe ieškoma naujų statistinių sprendimų erdvinei informacijai skaitmeniniuose vaizduose gauti ir naudoti. Erdvinė informacija nusako ryšį tarp erdvinių duomenų ir šių duomenų požymius. Daug dėmesio skiriama erdvinės koreliacijos įtakai panaudoti Bajeso diskriminantinėse funkcijose, įvedant erdvinę priklausomybę į apriorinių tikimybių įvertinimą. Analizuojami kaimynų parinkimo būdai ir jų įtaka klasifikavimo metodams.

Šiame darbe taip pat tiriami akies dugno vaizdų analizės metodai – daugiausia dėmesio skiriama kraujagyslių tinklo išskyrimui, kraujagyslių pločio matavimams ir arterijų ir venų pločių santykiui matuoti naudojamų kraujagyslių klasifikavimui.

Darbo tikslas – atrasti naujų statistinių sprendinių erdvinei informacijai skaitmeniniuose vaizduose naudoti ir ištirti jų taikymo akies dugno vaizdams analizuoti galimybes.

Darbo objektas – erdvinė informacija skaitmeniniuose vaizduose.

Disertacijoje pateikiama SCRDR (angl. *Spatial Classification Rule with Distance*) – erdvinė klasifikavimo taisyklė su atstumu. Pagal šią taisyklę apriorinės klasių tikimybės priklauso nuo mokymo imties išsidėstymo erdvėje. Didesnis tikslumas gaunamas, kai užtikrinamas tinkamas klasifikuojamo taško kaimynų parinkimas. Šis metodas sukurtas vaizdams su trimatėmis erdvinėmis koordinatėmis analizuoti taip, kad sudaroma nauja galimybė jį taikyti kompiuterinės tomografijos ar magnetinio rezonanso vaizduose esantiems objektams klasifikuoti.

Sukurti akies dugno kraujagyslių matavimo bei arterijų ir venų pločių santykiui apskaičiuoti naudojamų kraujagyslių klasifikavimo metodai. Matuojant kraujagyslių plotį taikomas kraujagyslės profilio gavimo metodas, paremtas erdvine funkcija. Tai leidžia analizuoti profilio informaciją nepaisant pradinio vaizdo rezoliucijos dydžio – matavimų metodas yra adaptyvus skirtingiems vaizdų dydžiams. Klasifikuojant kraujagysles naudojami nauji pasiūlyti požymiai, normalizuojami atsižvelgiant į kraujagyslių išsidėstymą erdvėje, ir taip sumažinama netolygaus vaizdų apšvietimo įtaka.

Disertaciją sudaro 5 skyriai ir literatūros sąrašas. Visa disertacijos apimtis yra 110 puslapių, pateikti 36 paveikslai ir 10 lentelių.

Tyrimų rezultatai publikuoti 2-uose periodiniuose recenzuojamuose leidiniuose, 5-iuose recenzuojamuose konferencijos pranešimų medžiagos leidiniuose, pristatyti ir aptarti 11-oje nacionalinių ir tarptautinių konferencijų.

PAVEIKSLĖLIŲ SĄRAŠAS

1 pav.	Duomenys, informacija ir žinios vaizdų analizėje.	20
2 pav.	Struktūrinių elementų pavyzdžiai.	22
3 pav.	Daugiasluoksnio dirbtinio neuroninio tinklo schema.	25
4 pav.	Mašininio mokymo ir giliojo mokymosi metodų skirtumai.	26
5 pav.	Konvoliucinio neuronų tinklo veikimo iliustravimas.	27
6 pav.	Skirtinga įranga gauti skirtingos raiškos vaizdai.	30
7 pav.	Probleminiai akies dugno vaizdai.	31
8 pav.	Erdvinės situacijos iliustracija.	44
9 pav.	Keletas eksperimente naudotų pradinių paveikslėlių.	49
10 pav.	Eksperimento ruošimo schema. 100 skirtingų paveikslėlių su 4- iomis skirtingomis α reikšmėmis.	50
11 pav.	Eksperimento su vienu iš paveikslėlių vizualūs rezultatai.	51
12 pav.	Triukšmo įtakos eksperimentinio tyrimo schema.	53
13 pav.	Eksperimento rezultatai. Bendras klasifikavimo tikslumas.	54
14 pav.	Klasifikavimo tikslumo koreliacijos pločio atžvilgiu tyrimo rezultatai.	54
15 pav.	Probleminė situacija, kai klasifikuojamo taško aplinkoje nėra atitinkamos klasės taškų iš mokymo imties.	55
16 pav.	Skirtingų kaimynų parinkimo būdų grafinis vaizdavimas.	56
17 pav.	Kaimynysčių schemas įtakos eksperimentinio tyrimo schema.	59
18 pav.	Kaimynų parinkimo būdų įtakos eksperimento rezultatai.	60
19 pav.	Eksperimento schema. Pagal šią schemą sugeneruota ir suklasifikuota 100 skirtingų objektų.	62
20 pav.	Trimačių vaizdų klasifikavimo tyrimo rezultatai.	62
21 pav.	Automatinės akių dugno analizės metodikos iliustracija.	66
22 pav.	Kraujagyslių identifikavimas ir išmatavimas. Balta spalva – OD_r . Mėlyna – OD_{mit} centras. Mėlyni brūkšneliai – arterijos, raudoni brūkšneliai – venos.	67
23 pav.	Visa akies dugno kraujagyslių pločio matavimo metodo schema.	70
24 pav.	Kraujagyslių tinklo išskyrimo schema.	72
25 pav.	Optinio disko nustatymo etapo schema.	73
26 pav.	Vaizdų paruošimas automatiniais kraujagyslių pločio matavimams.	74
27 pav.	Kraujagyslės profilio gavimo schema.	75
28 pav.	Profilio analizė: kraujagyslės pločio įvertinimas.	76
29 pav.	Matavimo metodo etapų iliustracija.	76

30 pav.	Kraujagyslių pločių matavimų rezultatai. Matavimai atlikti ekspertų ir pateikto metodo: a) sklaidos diagrama, b) Bland-Altman diagrama.	77
31 pav.	Arterijų ir venų santykio rezultatai. Matavimai atlikti ekspertų ir pateikto metodo: a) sklaidos diagrama, b) Bland-Altman diagrama.	78
32 pav.	Pagrindinės adaptyvumo ypatybės, lyginant su ne tokiais adaptyviais metodais.	81
33 pav.	Pagrindiniai AVR įvertinimo metodo žingsniai.	82
34 pav.	Dviejų etapų OD nustatymo schema, naudojama AVR matavimuose.	83
35 pav.	Kraujagyslės profilio analizės schema.	85
36 pav.	Pagrindiniai AVR analizės elementai. Naudojamas vaizdas iš INSPIRE-AVR duomenų bazės (Niemeijer et al., 2011).....	87

LENTELIŲ SĄRAŠAS

Lentelė 1.	Bendri klasifikavimo tikslumo rezultatai.	52
Lentelė 2.	Vidutinis ir minimalus klasifikavimo tikslumas pagal α parametą.	52
Lentelė 3	Eksperto rezultatai.....	59
Lentelė 4.	Kraujagyslių matavimo rezultatų charakteristikos.....	77
Lentelė 5.	Arterijų ir venų pločio santykis, apskaičiuotas 172 kraujagyslių poroms.	78
Lentelė 6.	Kraujagyslių išskyrimo ir klasifikavimo statistikos.....	88
Lentelė 7.	Lyginimui naudotų metodų tikslumo rezultatai.....	88
Lentelė 8.	Rezultatai naudojant klasifikavimo su mokymu metodus.	90
Lentelė 9.	Vidutinis klasifikavimo tikslumas su skirtingais metodais.	90
Lentelė 10.	Tyrimo rezultatai, kai požymiai normalizuojami nepriklausomai nuo objektų erdvinio išsidėstymo.....	91

ŽYMĖJIMAI

Toliau pateikiami disertacijoje naudojamų simbolių ir žymėjimų paaiškinimai.

SIMBOLIAI

$Z(s)$	atsitiktinio Gauso lauko (GRF) stebėjimai.
s, u	stebėjimo lokacija.
μ_l	l -osios klasės pastovus vidurkis.
$\hat{\mu}_{lt}^0$	l -osios klasės vidurkio sąlyginis įvertinys.
$\hat{\Psi}$	parametrų įvertinių vektorius.
$r(h)$	erdvinės koreliacijos funkcija.
R	mokymo imties objektų erdvinės koreliacijos matrica.
$d(s, u)$	atstumo tarp lokacijų funkcija. Visur naudojama Euklido atstumo funkcija.
α	erdvinės koreliacijos pločio parametras.
$\gamma(k)$	klasių žymių apriorinių tikimybių santykio logaritmas.
$\pi_l(y)$	l -osios klasės apriorinė tikimybė, priklausanti nuo mokymo imties.
$W_{tk}(Z_0; \hat{\mu}; \hat{\sigma}^2)$	įterptoji Bajeso diskriminantinė funkcija.
I	vaizdo taškų reikšmes atitinkanti matrica.
p_s	akies dugno vaizdams naudojamas skalės parametras.
I_{tr}	kraujagyslių tinklo vaizdo matrica.
OD	akies dugno optinis nervų diskas.
OD_{init}	surastas pradinis akies dugno optinis nervų diskas.
OD_r	įvertintas realus akies dugno optinis nervų diskas.
r_{OD}	optinio nervų disko spindulys.

SANTRUMPOS

AUC	plotas po ROC kreive (angl. <i>Area Under Curve</i>).
AVR	arterijų ir venų pločio santykis (angl. <i>Artery-Vein Ratio</i>).
CLAHE	riboto kontrasto adaptyvus histogramos išlyginimas (angl. <i>Contrast Limited Adaptive Histogram Equalization</i>)
DNT	dirbtinių neuroninių tinklų metodas (angl. <i>Artificial Neural Network</i>).
DT	sprendimų medžių klasifikavimo metodas (angl. <i>Decision Tree Classifier</i>).
FOV	žvalgos zona (angl. <i>Field Of View</i>).
GRF	atsitiktinis Gauso laukas (angl. <i>Gaussian Random Field</i>).
LDA	tiesinės diskriminantinės analizės klasifikavimo metodas (angl. <i>Linear Discriminant Analysis</i>).
Logit	multinominės logistinės regresijos klasifikavimo metodas.
MI	mokymo imtis.
K-NN	K artimiausių kaimynų klasifikavimo metodas (angl. <i>K Nearest Neighbors Classifier</i>).
PBDF	įterptoji Bajeso diskriminantinė funkcija (angl. <i>Plug-in Bayes Discriminant Function</i>).
RF	atsitiktinių medžių klasifikavimo metodas (angl. <i>Random Fields</i>).
ROC	sprendimus priimančiojo ypatybių kreivė (angl. <i>Receiver Operating Curve</i>).
ROI	dominantis regionas (angl. <i>Region of Interest</i>).
SCRD	erdvinio klasifikavimo taisyklė su atstumu (angl. <i>Spatial Classification Rule with Distance</i>).
Se	jautrumas (angl. <i>Sensitivity</i>).
Sp	specifiškumas (angl. <i>Specificity</i>).
SVM	atraminių vektorių metodas (angl. <i>Support Vector Machine</i>).

TURINYS

1. ĮVADAS.....	13
1.1. Tyrimų sritis	13
1.2. Darbo aktualumas	13
1.3. Darbo tikslas ir uždaviniai	15
1.4. Mokslinis naujumas.....	15
1.5. Ginamieji teiginiai	16
1.6. Darbo rezultatų aprobavimas	16
1.7. Disertacijos struktūra	18
2. ERDVINĖ INFORMACIJA IR VAIZDŲ ANALIZĖ	19
2.1. Erdviniai duomenys ir informacija	19
2.2. Erdvinės informacijos gavimas iš vaizdų.....	20
2.2.1. Matematinės morfologijos metodai	22
2.3. Erdvinė informacija klasifikavimui	23
2.3.1. Geostatistiniai klasifikavimo metodai.....	24
2.3.2. Giliojo mokymosi metodai	25
2.4. Akies dugno vaizdų analizė	28
2.4.1. Arterijų ir venų klasifikavimo metodai	33
2.4.2. Akies dugno vaizdų bazės	36
2.5. Skyriaus išvados	38
3. ERDVINĖ KLASIFIKAVIMO TAISYKLĖ	40
3.1. Metodo aprašymas.....	40
3.2. SCRD metodo algoritmas	45
3.3. Metodo veikimo tyrimas	48
3.3.1. Eksperimento ruošimas.....	49
3.3.2. Eksperimento rezultatai	51
3.4. Triukšmo įtakos tyrimas	53
3.5. Klasifikuojamo erdvės taško kaimynų parinkimas	55
3.5.1. Kaimynų parinkimo būdų algoritmai.....	56

3.5.2. Kaimynų parinkimo būdų tyrimas	59
3.6. Išplėtotas SCRD metodas duomenims 3D erdvėje.....	60
3.6.1. Eksperimentinis tyrimas	61
3.6.2. Tyrimo rezultatai	62
3.7. Skyriaus išvados	63
4. AKIES DUGNO KRAUJAGYSLIŲ KLASIFIKAVIMAS.....	64
4.1. Akių dugno analizės metodikos pagrindai	65
4.2. Akies dugno kraujagyslių matavimas	67
4.2.1. Skalės parametro apskaičiavimas	70
4.2.2. Kraujagyslių išskyrimas ir optinio nervų disko nustatymas	71
4.2.3. Kraujagyslių pločio matavimų metodas.....	73
4.2.4. Kraujagyslių pločio matavimų rezultatai	77
4.3. Adaptyvus AVR matavimams naudojamų kraujagyslių klasifikavimas.....	78
4.3.1. AVR įvertinimo metodas	80
4.3.2. Optinio nervų disko išskyrimas	82
4.3.3. Kraujagyslių matavimų pritaikymas	84
4.3.4. Požymių išskyrimas ir klasifikavimas.....	85
4.3.5. Klasifikavimo rezultatai.....	88
4.3.6. Klasifikavimo lyginimas su įprastais metodais	89
4.4. Skyriaus išvados	91
5. IŠVADOS IR REKOMENDACIJOS	93
LITERATŪROS SĄRAŠAS.....	95
AUTORIAUS PUBLIKACIJŲ SĄRAŠAS DISERTACIJOS TEMA	108

1. ĮVADAS

1.1. Tyrimų sritis

Pagrindinis vaizdų analizės tikslas – iš vaizduose esančios informacijos gauti tiriamai sričiai reikalingų žinių, kurios paskui naudojamos sprendimams priimti. Erdvinė informacija nusako ryšį tarp erdvinių duomenų ir šių duomenų požymius. Vaizdų analizėje objektais, kuriems būdinga erdvinė informacija, yra laikomi visi vaizdai, tam tikros vaizde ar vaizdų rinkiniuose esančios sritys ir atskiri vaizdo taškai. Šiame darbe yra nagrinėjamas erdvinės informacijos naudojimas vaizduose ir jų rinkiniuose (vaizduose su trimatėmis erdvinėmis koordinatėmis) esantiems objektams – atskiriems taškams ir taškų rinkiniams – tirti. Tokią objektų visumą nusako ne tik padėtis erdvėje, bet ir jų tarpusavio ryšiai: erdvinis atstumas, erdvinė priklausomybė – erdvinė autokoreliacija, klasių žymių informacija ir kita su objektais susieta statistinė informacija. Taip pat nagrinėjamos ir vaizduose esančių objektų erdvinės informacijos naudojimo kitai informacijai gauti galimybės, t. y. vaizdo dydžio ar jame esančio pagrindinio objekto dydžio naudojimas analizės metodų universalumui gauti.

1.2. Darbo aktualumas

Duomenų rinkimas skaitmeninių vaizdų pavidalu yra neatsiejamas nuo daugelio šiandieninio gyvenimo sričių. Vaizdai renkami ir archyvuojami beveik visose srityse. Dėl vaizdų gavimo techninės įrangos pažangos vaizdų gavimas, kaupimas ir analizė tampa neatsiejama biomedicinos, inžinerijos, gamtos bei socialinių mokslų dalimi. Vaizdų analizė jau yra svarbus informacijos gavimo įrankis, o tobulėjant vaizdų gavimo įrangai atsiranda naujų iššūkių ir galimybių.

Erdvinės informacijos naudojimo vaizdų klasifikavimui galimybės tyrinėjamos jau seniai (Haralick, 1979), o tobulėjant techninėms duomenų analizės galimybėms šių tyrimų aktualumas tik didėja (Wang et al., 2016). Vaizdų analizės ir apdorojimo praktikoje yra naudojama labai daug įvairių metodų, sukurtų seniai ir tinkamų daugeliui problemų spręsti. Tačiau šie metodai tyrinėjami ir tobulinami dar ir šiandien (žr. Wang et al., 2016, Miri et al., 2017, Troya-Galvis et al., 2018). Daug dėmesio skiriama vaizdų filtravimo (žr. Mun et al., 2018, Guo et al., 2018), objektų išskyrimo, segmentavimo, atpažinimo, klasifikavimo (žr. Öztürk et al., 2018, Krishnan et al., 2018) ir kitiems metodams.

Vienas iš vaizdų klasifikavimo keblumų yra stebimo vaizdo suskirstymas į keletą atskirų regionų sužymint vaizdo taškus. Tai atliekama atsižvelgiant į taškų požymius ir į informaciją apie erdvinius sąryšius su mokymo imtimi. P. Switzeris buvo pirmasis, pritaikęs erdvinės informacijos sąryšius klasifikavimui (Switzer, 1980). Vaizdų klasifikavimui plačiai taikomi geostatistiniai metodai. Šie metodai remiasi erdvine autokoreliacija, ja nurodomas laipsnis, kuriuo koreliacija keičiasi kintant atstumui tarp objektų (Liu et al., 2009), ir ji tyrinėjama daugelio autorių siūlomuose metoduose (žr. Atkinson et al., 2009, Comber, 2013, Li, et al., 2014). Erdvinė autokoreliacija taikoma Bajeso diskriminantinėse funkcijose, kai vertinami parametrai laikomi nekoreliuojantys su mokymo imties objektais. Straipsnyje (Dučinskas, 2009) įvestas parametru vertinamas atsižvelgiant į erdvinę priklausomybę su mokymo imtimi. Bajeso diskriminantinių funkcijų taikymas vaizdų analizėje ir erdvinės koreliacijos įtaka nagrinėtos disertacijoje (Stabingienė, 2012).

Akies dugno kraujagyslės yra vienintelės žmogaus kraujagyslės, kurios gali būti stebimos neinvaziniu vaizdų gavimo būdu (Miri et al., 2017), (Fraz et al., 2014). Akies dugno vaizdams yra dažnai taikoma rankinė ir automatinė struktūros analizė (Mirsharifa et al., 2013), (Sim et al., 2015). Ši analizė padeda lengviau diagnozuoti ligas, tad ypač tai aktualu ankstyvosiose ligos stadijose (Li et al., 2014). Daugybė ligų gali būti iš anksto diagnozuotos iš akies dugno vaizdų remiantis keletu skirtingų požymių. Oftalmologai sieja tam tikrus arterijų ir venų pločių požymius su tokiomis ligomis, kaip diabeto retinopatija, aterosklerozė, hipertenzija ir kt. Ligos paveikia arterijas ir venas, tad susiformuoja neįprastas jų pločių santykis.

Pastaruoju metu, kai atsirado daugiau techninių galimybių, pradėti tyrinėti ir taikyti giliojo mokymosi (angl. *Deep Learning*) metodai (LeCun et al., 2015). Vaizdų analizėje pradėti plačiai taikyti konvoliuciniai neuroniniai tinklai (Krizhevsky et al., 2012), padedantys išspręsti labai sudėtingas problemas. 3D konvoliucinis neuroninis tinklas taikomas žmogaus veiksams atpažinti iš vaizdo medžiagos (Ji et al., 2013). Adaptyvi gestų atpažinimo sistema publikuota straipsnyje (Neverova et al., 2016). Žmogaus veido analizės galimybės „DeepFace“ sistemoje pateiktos straipsnyje (Taigman et al., 2014). Taip pat tiriamos ir pačių metodų galimybės (Yosinski et al., 2014). Ne išimtis tapo ir akies dugno vaizdų analizė, čia ji taikoma įvairiose srityse (Almotiri et al., 2018). Konvoliuciniuose neuroniniuose tinkluose naudojama iš skaitmeninių vaizdų gauta informacija apie juose esančius objektus įvairiais vaizdų apdorojimui plačiau taikomais filtrais. Taip pat informacijos trūkumo problemos sprendžiamos vaizdų augmentacija,

kurioje taip pat taikomi įvairūs vaizdų analizės metodai. Šie pavyzdžiai iliustruoja tai, kad žinios apie skaitmeniniuose vaizduose esančius dėsningumus gali būti panaudotos ir tobulinant esamus ar kuriant naujus tiek giliojo mokymosi, tiek ir kitus ateityje tapsiančius aktualius metodus.

1.3. Darbo tikslas ir uždaviniai

Darbo tikslas – atrasti naujų statistinių sprendinių erdvinei informacijai skaitmeniniuose vaizduose pritaikyti ir ištirti taikymo galimybes akies dugno vaizdams analizuoti.

Darbo objektas – erdvinė informacija skaitmeniniuose vaizduose.

Tikslui pasiekti sprendžiami uždaviniai:

1. Išanalizuoti erdvinės koreliacijos įtaką klasifikavimo su mokymu metodams.
2. Įvesti erdvinės koreliacijos įtaką į apriorinių klasės žymių statistinį tikimybių vertinimą Bajeso diskriminantinėse funkcijose.
3. Pasiūlyti naujus kaimynystės aprašymo būdus ir ištirti jų įtaką klasifikavimui. Rasti geriausią kaimynystės aprašymo būdą nuo mokymo imties nutolusių vaizdo vietų klasifikavimui.
4. Išanalizuoti akių dugno statistinius vaizdų analizės metodus, taikomus akies dugno kraujagyslių tyrimams.
5. Rasti erdvinės informacijos pritaikymo galimus statistinius sprendimus akies dugno kraujagyslių matavimams.
6. Pritaikyti erdvinę informaciją akies dugno kraujagyslių klasifikavimo problemoms spręsti.

1.4. Mokslinis naujumas

1. Sukurtas klasifikavimo metodas SCRD, kuriame klasių apriorinės tikimybės priklauso nuo mokymo imties atsižvelgiant į erdvinę koreliaciją.
2. Išanalizuota kaimynų parinkimo būdų įtaka klasifikavimo su mokymu tikslumui ir nustatytas tinkamiausias iš būdų SCRD metodu.
3. Erdviniu atstumu ir koreliacija paremtas klasifikavimo metodas SCRD apibendrintas duomenims su trimatėmis erdvinėmis koordinatėmis.
4. Sukurtas adaptyvus akies dugno vaizdų analizės metodas.
5. Erdvinio atstumo funkcija pritaikyta vaizdo profilio informacijai gauti ir taikoma kraujagyslių matavimams akies dugno vaizduose.
6. Sukurtas automatinis akies dugno kraujagyslių, naudojamų arterijų ir venų santykio skaičiavimams, klasifikavimo metodas paremtas požymių erdviu normalizavimu.

1.5. Ginamieji teiginiai

1. Apriorinės klasių žymių tikimybės priklauso nuo klasifikuojamo taško aplinkoje esančios mokymo imties elementų erdvinės koreliacijos.
2. Klasifikuojamo taško kaimynų parinkimo būdo pasirinkimas padeda tiksliau klasifikuoti vaizdų vietas, kurių aplinkoje trūksta vienos klasės mokymo imties elementų.
3. Erdvinių funkcijų taikymas vaizdo profilio informacijai gauti įgalina adaptyviai taikyti bendrą matavimo metodą skirtingų dydžių akies dugno vaizdams.
4. Erdvinis atstumas, taikomas klasifikavimui naudojamiems požymiams normalizuoti, padeda sumažinti netolygaus vaizdo apšvietimo sukeltą netikslumą.

1.6. Darbo rezultatų aprobavimas

Tyrimų rezultatai publikuoti 2-uose periodiniuose recenzuojamuose leidiniuose:

1. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, Lijana Stabingienė, Povilas Treigys, Ramutė Vaičaitienė, Adaptive eye fundus vessel classification for automatic artery and vein diameter ratio evaluation, *Informatica*, 2018, Vol. 29, No. 4, p. 757–771.
2. **Giedrius Stabingis**, Kęstutis Dučinskas, Lijana Stabingienė, Comparison of spatial classification rules with different conditional distributions of class label, *Nonlinear Analysis: Modeling and Control*, 2014, Volume 19, No 1, p. 109–117, MII, Vilnius. ISSN 1392-5113.

Tyrimų rezultatai publikuoti 5-iuose recenzuojamuose konferencijos pranešimų medžiagos leidiniuose:

1. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, Povilas Treigys, Ramutė Vaičaitienė, Lijana Stabingienė, Automatization of eye fundus vessel width measurements, *VipIMAGE 2017, Lecture Notes in Computational Vision and Biomechanics*, Volume 27, p. 787–796, 2017. Springer.
2. **Giedrius Stabingis**, Spatial classification rule with distance in three dimensional space, *Lietuvos matematikos rinkinys. Proc. LMS, Ser. A*, 2016, Vol. 57. p. 81–85, ISSN 0132-2818.

3. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Daiva Imbrasienė, Alvydas Paunksnis, Automated Classification of Arteries and Veins in the Retinal Blood Vasculature, *Computer data analysis and modeling. Theoretical & Applied Stochastics. Proceedings 11th International Conference*, 2016, p. 64–67. Minsk, Belarus.
4. **Giedrius Stabingis**, Lijana Stabingienė, Neighborhood scheme selection for classification with SCRD method, *Lietuvos matematikos rinkinys. Proc. LMS, Ser. A*, 2015, Vol. 56, p. 101–106. ISSN 0132-2818.
5. **Giedrius Stabingis**, Lijana Stabingienė, Application of spatial classification rules for remotely sensed images, *Lietuvos matematikos rinkinys. Proc. of the Lithuanian Mathematical Society, Ser. B*, 2014, Vol. 55, p. 63–67. ISSN 0132-2818.

Tyrimų rezultatai pristatyti ir aptarti 11-oje nacionalinių ir tarptautinių konferencijų:

1. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, Povilas Treigys, Ramutė Vaičaitienė, Lijana Stabingienė. Automatic Artery Vein Ratio Measurements in Eye Fundus Images. *Data Analysis Methods for Software Systems. 9th International Workshop*. Druskininkai, Lietuva. 2017.
2. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, Povilas Treigys, Ramutė Vaičaitienė, Lijana Stabingienė, Automatization of Eye Fundus Vessel Width Measurements. *VI ECCOMAS Thematic Conference on Computational Vision and Medical Image Processing Porto*. Portugalija. 2017.
3. **Giedrius Stabingis**, Jolita Bernatavičienė, Povilas Treigys, Alvydas Paunksnis, Ramutė Vaičaitienė, Viktor Medvedev. Automated Blood Vessels Diameter Measurement in Eye Fundus Images. *Data Analysis Methods for Software Systems. 8th International Workshop*. Druskininkai, Lietuva. 2016.
4. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Daiva Imbrasienė, Alvydas Paunksnis. Automated Classification of Arteries and Veins in the Retinal Blood Vasculature. *11th International Conference computer data analysis & modeling 2016 Theoretical & Applied Stochastics*. Minskas, Baltarusija. 2016.
5. Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, **Giedrius Stabingis**, Povilas Treigys. Automated Blood Vessel

- Detection and Pathological Changes Identification in Eye Fundus Images. *EURO 2016 – 28th European Conference on Operational Research*. Poznanė, Lenkija. 2016.
6. **Giedrius Stabingis**, Spatial classification rule with distance in three dimensional space. *Lietuvos matematikų draugijos 57-oji konferencija*. Vilnius, Lietuva. 2016.
 7. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Daiva Imbrasienė, Alvydas Paunksnis, Viktorija Slavinskytė, Povilas Treigys. Automated Blood Vessel Detection and Characteristic Evaluation in Eye Fundus Images. *Data Analysis Methods for Software Systems. 7th International Workshop*. Druskininkai, Lietuva. 2015.
 8. **Giedrius Stabingis**, Lijana Stabingienė, Neighborhood scheme selection for classification with SCR method. *Lietuvos matematikų draugijos 56-oji konferencija*. Kaunas, Lietuva. 2015.
 9. **Giedrius Stabingis**, Lijana Stabingienė. The influence of noise level to the accuracy of supervised classification methods. *Data Analysis Methods for Software Systems. 6th International Workshop*. Druskininkai, Lietuva. 2014.
 10. **Giedrius Stabingis**, Lijana Stabingienė, Application of spatial classification rules for remotely sensed images. *Lietuvos matematikų draugijos 55-oji konferencija*. Vilnius, Lietuva. 2014.
 11. Lijana Stabingienė, **Giedrius Stabingis**. The influence of noise level to the accuracy of supervised classification methods. *1st international conference on high performance computing and mathematical modelling*. Liepoja, Latvija. 2013.

1.7. Disertacijos struktūra

Disertaciją sudaro 5 skyriai ir literatūros sąrašas. Disertacijos skyriai: įvadas, erdvinė informacija ir vaizdų analizė, erdvinė klasifikavimo taisyklė, akies dugno kraujagyslių klasifikavimas ir išvados. Disertacijoje pateikti paveikslų, lentelių, naudotų santrumpų ir žymėjimų sąrašai. Visa disertacijos apimtis yra 110 puslapių, pateikti 36 paveikslai ir 10 lentelių. Disertacijoje remtasi 125 literatūros šaltiniais.

2. ERDVINĖ INFORMACIJA IR VAIZDŲ ANALIZĖ

2.1. Erdviniai duomenys ir informacija


Duomenys – tai objektyviai egzistuojantys faktai, vaizdai arba garsai, kurie gali būti naudingi tam tikram uždaviniui spręsti. Informacija – tai duomenys, kurių forma ir turinys yra pateikti tinkamu naudoti sprendimų priėmimo procese būdu. Duomenys virsta informacija, kai jiems suteikiamas kontekstas ir jie susiejami su tam tikra problema ar sprendimu. Žinios yra gebėjimas spręsti problemas, atnaujinti arba sukurti naujas vertes remiantis ankstesne patirtimi, įgūdžiais ar išmokimu. Tai žmogaus proto abstrakcija apie duomenis, jų prasmę, naudą ir sąryšius. Turimos žinios gali virsti informacija, kuri gali būti panaudota naujoms žinioms įgyti (Dzemyda et al., 2008). Informacija taip pat apibrėžiama kaip ryšys tarp duomenų ar duomenis atitinkančių objektų. Informacija – tai duomenys tam tikrame kontekste. Be konteksto duomenys yra bereikšmiai, interpretuodami su duomenimis susijusį kontekstą sukuriame reikšmingą informaciją.

Erdviniai duomenys – bet kokios žinios apie vietovę, formas, santykius tarp jų, geografines ypatybes. Erdvinių duomenų pagrindinė ypatybė – duomenų santykis su koordinacių sistema. Geostatistikoje erdviniai duomenys apibrėžiami kaip duomenys, tiesiogiai ar netiesiogiai susieti su tam tikra lokacija ar sritimi (Cressie 1993). Skaitmeniniuose vaizduose erdviniai duomenys siejami su vaizdo koordinatėmis ar vaizdo regionais (Wang et al., 2016).

Skaitmeninį 2D vaizdą sudaro taškų tinklelis. Taškas (angl. *pixel*) yra mažiausias vaizdo elementas. Kiekvienas vaizdo taškas atitinka vieną ar kelias reikšmes, kurios vadinamos taško intensyvumo reikšmėmis. Intensyvumo reikšmės skiriasi priklausomai nuo taško lokacijos $s(x, y)$, kur x atitinka vaizdo taško horizontalią poziciją, o y – vertikalią poziciją. Vaizdas $I(s)$ – tai funkcija, susiejanti vaizdo koordinatas (tašką) su intensyvumo reikšmėmis. Spalvoto vaizdo, užkoduoto *RGB* (angl. *Red, Green, Blue*) spalvų maišymu, atveju $I(s) = (I_R(s), I_G(s), I_B(s))$. Kadangi skaitmeniniuose vaizduose taškai išsidėstę vienodais atstumais \mathbb{R}^2 erdvėje, tai vaizdo taškų matrica atitinka vaizdo funkcijos $I(s)$ reikšmes tuose taškuose. Skaitmeniniuose vaizduose erdviniais duomenimis yra laikomos ir vaizdo koordinatės, ir koordinatės atitinkančios intensyvumų reikšmės.

Erdvinė informacija apibrėžia fizinę objektų prasmę ir ryšį tarp objektų. Vaizdų analizėje iš erdvinių duomenų gaunama erdvinė informacija susieja vaizdo taškus ar taškų sritis (Wang et al., 2008). Geografinėse informacinėse

sistemose naudojamuose vaizduose taikomas ryšys tarp vietovių, žmonių, veiklų ir kitų objektų (Wang et al., 2016). Erdvinės informacijos gausu ir mediciniuose vaizduose (Woods, 2009), čia anatominė informacija susieta su vaizdo koordinatėmis (Wei et al., 2010). Skaitmeniniams vaizdams yra būdinga klasterių, tekstūros, atstumo, koreliacijos, klasifikavimo ir kita erdvinė informacija. Ši informacija gaunama iš erdvinių duomenų ir toliau naudojama žinioms gauti ir sprendimams priimti, kaip pavaizduota 1 pav.



1 pav. Duomenys, informacija ir žinios vaizdų analizėje.

Formaliai erdvinis duomenis galime apibrėžti kaip erdvėje atliktų stebėjimų rezultatą. Kai stebėjimas atliekamas d -matės Euklido erdvės taške $s \in \mathbb{R}^d$, stebiny $Z(s)$ erdvės taške s yra atsitiktinis dydis. Tuomet matematinis erdvinis duomenų (erdvinės populiacijos) modelis yra atsitiktinis laukas (RF) $\{Z(s): s \in D\}$, kur $D \subset \mathbb{R}^d$ yra erdvinis indeksų aibė, o atsitiktinio lauko realizacija žymima $\{z(s): s \in D\}$.

Atsitiktinis laukas $\{Z(s): s \in D\}$ – tai rinkinys atsitiktinių dydžių, apibrėžtų vienoje tikimybinėje erdvėje (Ω, F, P) ir įgyjančių reikšmes erdvėje B . Erdvė B yra dažnai vadinama būsenų erdve. Čia ji yra $B \in \mathbb{R}^q$. Kai $q=1$, atsitiktinis laukas vadinamas skaliariniu, o kai $q>1$ – vektoriniu. Jei visi baigtiniamieji Z skirstiniai yra Gauso skirstiniai, s laukas vadinamas Gauso atsitiktiniu lauku (GRF) (angl. *Gaussian random field*), o jo stebiniai – Gauso duomenimis.

2.2. Erdvinės informacijos gavimas iš vaizdų

Vaizdų analizės ir apdorojimo praktikoje taikoma labai daug įvairių metodų (žr. Wang et al., 2016, Miri et al., 2017, Zhang et al., 2017, Troya-Galvis et al., 2018, Wang et al., 2017). Labai dažnai yra taikomi vaizdų filtravimo (žr. Mun et al., 2018, Guo et al., 2018), objektų išskyrimo (radimo), atpažinimo, klasifikavimo metodai (žr. Öztürk et al., 2018, Krishnan et al., 2018, Zhang et al., 2018).

Detali erdvinės informacijos pritaikymo nuotolinio stebėjimo (angl. *remote sensing*) vaizdų analizėje apžvalga pateikta straipsnyje (Wang et al., 2016). Šioje apžvalgoje išskiriamos keturios erdvinės informacijos pritaikymo sritys: apdorojimas prieš klasifikavimą, imties parinkimas, klasifikatoriai, apdorojimas po klasifikavimo ir tikslumo vertinimas. Apdorojimo prieš klasifikavimą metu erdvinė informacija naudojama vaizdo tekstūros analizėje, gaunant naujų požymių.

Vaizdo tekstūros analizėje naudojamos pilkumo lygio pasikartojimo matricos GLCM (angl. *Grey-Level Co-occurrence Matrixes*) (Haralick, 1979). Daugiausia tiriamos GLCM metodo taikymo įvairioms problemoms spręsti galimybės. Pats metodas mažai keitėsi, metodo vystymas buvo nukreiptas į skaičiavimų laiko mažinimą (Clausi et al., 2002) ir metodo taikymą sudėtingesnės kaip 2D struktūros vaizdų analizei (žr. Huang et al., 2014, Tsai et al., 2013).

Fraktalų geometrija aprašo objektų nereguliariąsias ir sudėtingas formas. Fraktalų dimensija yra laikoma tekstūros požymiu, naudojamu klasifikavimui (Sun, 2006). Taip pat naudojami požymiai, gaunami sujungus fraktalų dimensijos ir erdvinės koreliacijos statistikų informaciją (Pant et al., 2010). Geostatistiniai metodai taikomi erdvinio sąryšio tarp vaizdo taškų reikšmės nustatyti (Atkinson et al., 2000). Šie metodai remiasi semivariogramomis, iš kurių gaunami požymiai, atitinkantys semivariogramų reikšmes (žr. Maillard 2003, Berberoglu et al., 2007) ir jų parametrus (Balaguer et al., 2010).


Požymiams gauti taip pat taikomi įvairūs vaizdų filtravimo metodai. Ypač dažni Gaboro filtrai ir vilnelių transformacijos (angl. *wavelet transformations*). Šie du metodai charakterizuoja vaizdų tekstūrą keliomis skalėmis per skirtingus erdvinius dažnius arba kelis suskaidymo lygmenis (Myint et al., 2004), (Shi et al., 2003). Šie metodai taikomi tiek nespaltotiems vaizdams, tiek ir spalvotiems ar daugiaspektriems vaizdams, kai analizuojami visi vaizdo kanalai vienu metu (Shen et al., 2013), (Guo et al., 2014).

Matematinė morfologija arba morfologinė vaizdų analizė yra dar viena erdvinės informacijos gavimo metodų grupė (Serra, 2008), (Soille et al., 2002). Šie metodai iš vaizdo gauna arba pašalina objektus sąjungos, sankirtos ar kitais aišių operatoriais su tinkamai parinktais struktūriniais elementais. Daugiaspektriems vaizdams taikomi morfologinių profilių metodai (Benediktsson et al., 2005) ir morfologiniai atributų profiliai (Mura et al., 2010), naudojantys jau gautą erdvinę informaciją (formą, tekstūrą ir kt.) morfologijos profilių operacijoms supaprastinti.

2.2.1. Matematinės morfologijos metodai

Vaizdų analizėje dažnai yra taikomi matematinės morfologijos metodai (Serra, 1986), (Serra, 2008). Šie metodai neretai taikomi binariniams vaizdams, kur $I(s) \in \{0, 1\}$. Toliau glaustai pateikiamos pagrindinės morfologijos operacijos.

Matematinės morfologijos operacijose naudojamas struktūrinis elementas (angl. *structuring element, kernel*) B – dvimatė matrica, iš reikšmių sudaranti specifinę formą. 2 pav. pavaizduoti keli skirtingų formų ir dydžių struktūriniai elementai. Čia (a–c) yra binariniai, skirtingų formų ir dydžių struktūriniai elementai, o d) yra dvimatį Gauso skirstinį atitinkantis 5×5 dydžio struktūrinis elementas.



2 pav. Struktūrinių elementų pavyzdžiai.

Binariniams vaizdams dažnai naudojamos šios matematinės morfologijos operacijos.

- Erozijos operacija: $\mathbf{A} \ominus \mathbf{B} = \bigcap_{b \in \mathbf{B}} \mathbf{A}_{-b}$
- Auginimo operacija: $\mathbf{A} \oplus \mathbf{B} = \bigcup_{b \in \mathbf{B}} \mathbf{A}_b$
- Atidarymo operacija: $\mathbf{A} \circ \mathbf{B} = (\mathbf{A} \ominus \mathbf{B}) \oplus \mathbf{B}$
- Uždarymo operacija: $\mathbf{A} \cdot \mathbf{B} = (\mathbf{A} \oplus \mathbf{B}) \ominus \mathbf{B}$

Čia \mathbf{A} yra pradinis vaizdas, \mathbf{B} – struktūrinis elementas, o \mathbf{A}_b – \mathbf{A} perstūmimas per b .

Matematinė morfologija taip pat taikoma pilkiems vaizdams. Praktikoje tai pritaikyta akies dugno vaizdų analizėje kraujagyslių medžiui išskirti. Pilkiems vaizdams skirtoje morfologijoje vaizdai yra laikomi funkcijomis $f(x)$, vaizduojančiomis Euklido erdvę arba tinklę E į $\mathbb{R} \subset (-\infty; \infty)$, kur \mathbb{R} yra realiųjų skaičių aibė.

Nespalvotų vaizdų morfologijoje struktūrinis elementas yra to paties formato, kaip ir vaizdas, ir yra vadinamas struktūrine funkcija $b(x)$.

Auginimo funkcija šiuo atveju apibrėžiama taip:

$$(f \oplus b)(x) = \sup_{y \in E} [f(y) + b(x - y)]. \quad (1)$$

Erozijos funkcija apibrėžiama taip:

$$(f \ominus b)(x) = \inf_{y \in E} [f(x + y) - b(y)]. \quad (2)$$

Uždarymo ir atidarymo matematinės morfologijos funkcijos veikia taip pat kaip binariniu atveju.

Dar viena atliekama operacija yra ploninimo operacija. Šios operacijos metu nuolat kartojama operacijos seka, kol konverguoja.

$$A \otimes B_1 \otimes B_2 \otimes \dots \otimes B_8 \otimes B_1 \otimes B_2 \otimes \dots, \quad (3)$$

čia $A \otimes B_i = A (A \odot B_i)$ yra ploninimo operacijos žingsnis. $A \odot B_i = (A \ominus C_i) \cap (A^C \ominus D_i)$ yra morfologinė „hit or miss“ operacija. $B_i = (C_i, D_i)$ yra sudėtinis struktūrinis elementas, kuriam $C_i \cap D_i = \emptyset$. A^C yra A papildinys.

Struktūriniai elementai įgyja šias formas:

$$C_1 = \begin{pmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ 1 & 0 & 0 \end{pmatrix}, D_1 = \begin{pmatrix} 0 & 0 & 1 \\ 0 & 0 & 1 \\ 0 & 0 & 1 \end{pmatrix}, \quad (4)$$

$$C_2 = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 0 \end{pmatrix}, D_2 = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 1 \end{pmatrix}.$$

Kiti struktūriniai elementai yra ankščiau apibrėžti elementai, pasukti nurodytu kampu: $C_3 = C_{1,90^\circ}$, $C_4 = C_{2,90^\circ}$, $C_5 = C_{1,180^\circ}$, $C_6 = C_{2,180^\circ}$, $C_7 = C_{1,270^\circ}$, $C_8 = C_{2,270^\circ}$, $D_3 = D_{1,90^\circ}$, $D_4 = D_{2,90^\circ}$, $D_5 = D_{1,180^\circ}$, $D_6 = D_{2,180^\circ}$, $D_7 = D_{1,270^\circ}$, $D_8 = D_{2,270^\circ}$.

2.3. Erdvinė informacija klasifikavimui

Erdvine informacija (vaizdo tekstūros, krypties, artumo ir kt.) grindžiamos vaizdų klasifikavimo problemos sprendžiamos jau daug metų (Haralick, 1979). Klasifikavimo metodus galima suskirstyti į dvi grupes: kai

klasifikuojami vaizde išskirti objektai, susidedantys iš vaizdo taškų grupių, ir kai klasifikuojami atskiri taškai.

Vaizde esantiems objektams klasifikuoti būtinas objektų išskyrimas iš vaizdo. Segmentavimo metodai skirstomi į tris kategorijas: erdvės, spektro ir erdvės-spektro (Fauvel et al., 2013). Vienas iš šių metodų keblumų yra tinkamo mastelio parinkimas (Blaschke, 2010). Kadangi realus objektų vaizde dydis būna nežinomas, netinkamai parinkus segmentavimo mastelį, vaizde esantys objektai gali būti praleidžiami arba sujungiami į vieną.

Taškams klasifikuoti plačiai taikomi kontekstiniai atraminių vektorių metodai (Fauvel et al., 2013, Camps-Valls et al., 2014). Siūlyti SVM metodai, jungiantys erdvės ir spektro informaciją (Camps-Valls et al., 2014). Taikomi įvairūs Markovo atsitiktiniais laukais paremti metodai (Moser et al., 2013). Analizuojant vaizdus apibendrinama 1D Markovo grandinės koncepcija 2D sistemai. Taip charakterizuojama kontekstinė informacija išnaudojant kaimyninių taškų nenutrūkstumą. Taškams klasifikuoti taip pat taikomi geostatistiniai metodai.

2.3.1. Geostatistiniai klasifikavimo metodai

W. Toblerio pirmasis geografinės dėsnis teigia, kad viskas yra susiję su viskuo kitu, bet arčiau esantys objektai yra labiau susiję už tolimesnius (Tobler, 1970). Šis dėsnis apibūdina erdvinę autokoreliaciją, nurodančią, kaip koreliacija kinta keičiantis atstumui (Liu et al., 2009).

Moksliniuose straipsniuose (Atkinson, 2004), (Atkinson et al., 2009), (Oliver et al., 1989) požymių geostatistinės informacijos naudojimas klasifikatoriuose yra paremtas klasifikuojamų objektų marginaliniais skirstiniais.

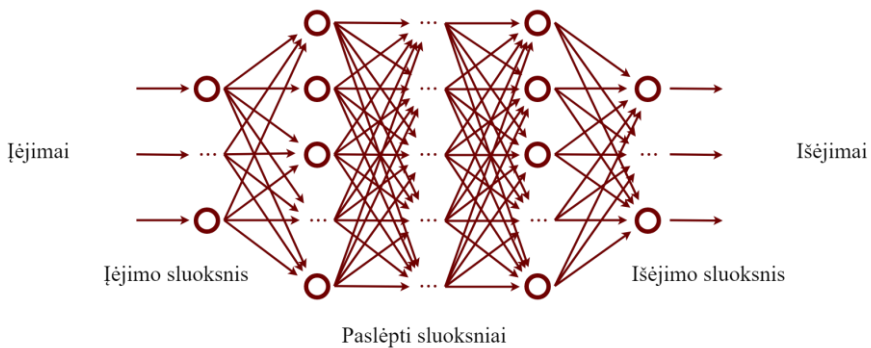
Straipsnyje (Dučinskas, 2009) aptariamas Gauso atsitiktinio lauko stebėjimų klasifikavimas. Autorius siūlo klasifikuojant atsižvelgti į klasifikuojamų taškų artumą, t. y. į šių stebėjimų požymių reikšmių koreliaciją, būdingą erdviniam duomenims. Daugiamatis metodo atvejis ir klaidos tikimybės pateiktos straipsnyje (Dučinskas, 2011).

Erdvinės koreliacijos įtaka diskriminantinėms funkcijoms tirta straipsnyje (Stabingienė et al., 2010). Straipsnyje (Stabingienė et al., 2011) pateiktame metode požymiai modeliuojami stacionariu Gauso atsitiktiniu lauku, o klasių žymėms modeliuoti taikomas Markovo atsitiktinio lauko modelis. Šiame metode pakeista sąlyginės nepriklausomybės prielaida – klasifikuojami objektai laikomi priklausomais nuo mokymo imties objektų. Straipsnyje (Dučinskas et al., 2011) tirtos pateikto metodo klaidos tikimybės. Metodo

taikymai publikuoti straipsnyje (Dučinskas et al., 2011). Šis metodas pritaikytas realioje situacijoje klasifikuojant nuotolinio stebėjimo vaizdus straipsnyje (Stabingienė, 2012a). Šių tyrimų pagrindu apginta daktaro disertacija (Stabingienė, 2012b).

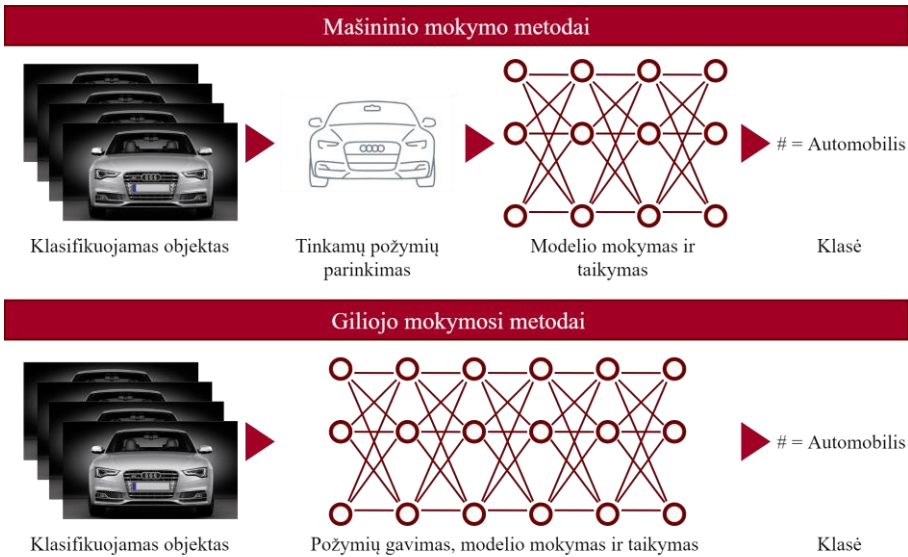
2.3.2. Giliojo mokymosi metodai

Gilusis mokymasis (angl. *Deep Learning*) skirtas modeliams iš kelių informacijos apdorojimo lygmenų, kad būtų išmokti pateiktų duomenų dėsningumai keliais abstrakcijos lygmenimis (LeCun et al., 2015). Giliojo mokymosi neuroninis tinklas jungia keletą daugialypių netiesiškai apdorojamų sluoksnių paprastais lygiagrečiai veikiančiais elementais (metodais). Šie tinklai sudaryti iš įėjimo sluoksnio, keleto paslėptų sluoksnių ir išėjimo sluoksnio. Sluoksniai tarpusavyje sujungti mazgais (neuronais), kiekviename paslėptame sluoksnyje kaip įėjimai naudojami ankstesnio sluoksnio išėjimai. 3 pav. pateikta bendroji daugiasluoksnio dirbtinio neuroninio tinklo schema.



3 pav. Daugiasluoksnio dirbtinio neuroninio tinklo schema.

Daugiasluoksnis neuroninis tinklas yra viena iš dažniausiai taikomų mašininio mokymo priemonių. Giliojo mokymosi metodai yra mašininio mokymo metodų šaka. 4 pav. pateiktas pagrindinis skiriamasis bruožas, būdingas giliojo mokymosi metodams. Šios grupės metodai patys gauna sprendimams priimti reikalingus požymius. Kitiems mašininio mokymo metodams naudojami požymiai yra gaunami kitomis priemonėmis ir naudojami mokymui bei sprendimams priimti.




4 pav. Mašininio mokymo ir giliojo mokymosi metodų skirtumai.

Giliojo mokymosi metodai ypač palengvino kalbos ir vizualinio objektų atpažinimo, objektų aptikimo ir kitų problemų sprendimą. Giliojo mokymosi metodai didelėse duomenų aibėse atranda sudėtingas duomenų struktūras. Dažnai yra taikomi sklidimo atgal algoritmai norint nustatyti, kaip sistemos vidiniai parametrai turi keistis, kad būtų įvertinti duomenų dėsningumai kiekviename lygmenyje pagal ankstesnio lygmens duomenų dėsningumus. Vaizdams klasifikuoti pastaruoju metu pradėti plačiai taikyti gilaus mokymo konvoliuciniai neuroniniai tinklai CNN (angl. *Convolutional Neural Networks*).

Konvoliucinių neuroninių tinklų taikymo pradžia laikomas straipsnis (Fukushima, 1980). Tačiau šis metodas didžiausio susidomėjimo sulaukė, kai juo remiantis pasiektas labai aukštas vaizdų klasifikavimo tikslumas ImageNET konkurse (Krizhevsky et al., 2012). Konvoliuciniai neuroniniai tinklai naudoja konvoliuciją tarp vaizdo ir tam tikrų struktūrinių elementų matricių. Konvoliucija arba sąsuka – tai signalų apdorojimo veiksmas, kuris iš dviejų pirminių masyvų – šablono (struktūrinio elemento) ir apdorojamo vaizdo – suskaičiuoja naują vaizdą. Ši technika plačiai taikoma daugeliui iš vaizdų analizės metodų: vaizdų filtravimui, morfologinei analizei, kontūro išskyrimui ir kt. Tai erdvinės informacijos gavimo iš erdviųjų duomenų būdas. Pradinis vaizdas apdorojamas su daug skirtingų filtrų, naudojant konvoliuciją, o tada gautiems rezultatams pritaikoma aktyvacijos funkcija. Dėl skaičiavimo paprastumo dažniausiai yra naudojama *ReLU* aktyvacijos funkcija. Po to

vaizdas sumažinamas ir sujungiami artimų taškų informacija pagal vieną iš statistinių funkcijų. Procesas kartojamas, kol pasiekiamas pakankamai mažas matricos dydis, kurį galima vektorizuoti ir pateikti į daugiasluoksnį neuroninį tinklą kaip įėjimo vektorius. Konvoliucinio neuroninio tinklo principas iliustruojamas 5 pav. (LeCun et al., 2015).



5 pav. Konvoliucinio neuronų tinklo veikimo iliustravimas.

Giliojo mokymosi metodai turi daug mokymo sluoksnių, kiekviename iš jų apibendrinama ankstesnio sluoksnio informacija, taip išmokstama vis sudėtingesnė analizuojamo objekto struktūra. Pavyzdžiui, AlexNet (Krizhevsky et al., 2012) tinklas yra sudarytas iš 650.000 neuronų, kuriuos jungia 630.000.000 jungčių, o šio tinklo mokymo procese reikia įvertinti 60.000.000 parametrų. Tokio sudėtingumo procesams užtikrinti reikia labai didelio kiekio duomenų. Konvoliucinių neuroninių tinklų atveju, jei mokoma daug skirtingų klasių apimanti problema, reikia labai didelio kiekio kiekvienos klasės vaizdų. Tokio tinklo apmokymas reikalauja labai daug laiko ir skaičiavimų resursų. Taip yra, nes mokymo proceso metu metodas turi įvertinti didelį kiekį parametrų, gaunamų įvairiose ir skirtingose situacijose

Mokymui skirtų vaizdų kiekiui sumažinti dažnai taikomas jau apmokytas konvoliucinis neuroninis tinklas. Iš jau apmokyto tinklo pašalinama kelių paskutinių sluoksnių mokymo informacija, pakeičiamos išėjimo sluoksnio klasės ir tinklas apmokomas su naujais vaizdais. Šis būdas dažnai naudojamas su AlexNet (Krizhevsky et al., 2012) tinklu, kai kuriamas naujas konvoliucinis tinklas, skirtas kitų klasių vaizdams klasifikuoti. Šis būdas taip pat sutrumpina tinklo mokymo procesą ir sumažina skaičiavimo resursų poreikį.

Kitas mokymui reikalingų pradinė vaizdų kiekio mažinimo būdas yra vaizdų augmentacija (angl. *Image Augmentation*). Naudojant augmentaciją iš pradinio mokymui skirtu vaizdu sugeneruojama daug papildomų vaizdų.

AlexNet (Krizhevsky et al., 2012) tinklo mokymui buvo naudojami 256x256 taškų dydžio vaizdai, o į tinklą tiekiami atsitiktinai iškirpti 224x224 dydžio vaizdai ir jų veidrodiniai atspindžiai. Be šių transformacijų dar naudojami pasukti vaizdai ir kitos vaizdų transformacijos. Atliekamos kontrasto, šviesinimo ir kitų vaizdo ypatybių keitimo operacijos (žr. Chollet, 2018), kaip kontrasto ištempimo (angl. *Contrast Stretching*), histogramos išlyginimo (angl. *Histogram Equalization*) ar CLAHE.

Gilioju mokymusi grįsti metodai pastaruoju metu padeda išspręsti labai sudėtingų problemų. 3D konvoliucinis neuroninis tinklas taikomas žmogaus veiksams atpažinti iš vaizdo medžiagos (Ji et al., 2013). Adaptyvi gestų atpažinimo sistema publikuota straipsnyje (Neverova et al., 2016). Žmogaus veido analizės galimybės „DeepFace“ sistemoje pateiktos straipsnyje (Taigman et al., 2014). Taip pat tiriamos pačių metodų galimybės: straipsnyje (Yosinski et al., 2014) nagrinėjamas informacijos perdavimas iš vieno neuroninio tinklo sluoksnio į kitą.

Šiame darbe giliojo mokymosi metodai yra tik apžvelgiami. Šie metodai dėl savo skirtingo sudėtingumo nėra lyginami su darbe nagrinėjamais metodais. Disertacijoje nagrinėjama iš skaitmeninių vaizdų statistiniais sprendimais gaunama erdvinė informacija, o atlikti tyrimai gali būti panaudoti tobulinant dabartinius ar kuriant naujus giliojo mokymosi metodus. Kaip jau minėta, konvoliuciniai neuroniniai tinklai naudoja iš skaitmeninių vaizdų gautą erdvinę informaciją apie juose esančius objektus įvairiais vaizdams apdoroti plačiau taikomais filtrais. Taip pat informacijos trūkumo problemos sprendžiamos vaizdų augmentacija, kurioje taip pat taikomi įvairūs vaizdų analizės metodai. Šie pavyzdžiai iliustruoja tai, kad nors giliojo mokymosi metodai automatiškai nustato mokymui reikalingus požymius, žinios apie skaitmeniniuose vaizduose esančius dėsningumus gali tapti priemone giliojo mokymosi ir kitiems metodams vystyti.

2.4. Akies dugno vaizdų analizė

Akies dugno kraujagyslės yra vienintelės žmogaus kraujagyslės, kurios gali būti stebimos neinvaziniu vaizdų gavimo būdu (Miri et al., 2017), (Fraz et al., 2014). Akies dugno vaizdams dažnai taikoma rankinė ir automatinė struktūros analizė. Ši analizė padeda lengviau diagnozuoti ligas, ypač tai aktualu ankstyvosiose ligos stadijose (Li et al., 2014). Išskirtos ligos, kurios gali būti nustatomos analizuojant akies dugno vaizdus:

- Geltonosios dėmės ploto degeneracija.

- Diabetinė retinopatija.
- Aterosklerozė.
- Glaukoma.

Pirmieji klinikiniai požymiai ankstyvojoje diabeto retinopatijos stadijoje aptinkami kraujagyslių anomalijose (Miri et al., 2017). Viena iš diabetinės retinopatijos anomalijų yra arterijų ir venų diametrų santykio – *AVR* pokytis. Įprastai sveiko žmogaus *AVR* yra apie 0,7 (Sun et al., 2009). Diabetine retinopatija sergančio žmogaus santykis didesnis, nes arterijos išsiplečia. Šiam požymiui apskaičiuoti kraujagyslės yra matuojamos specialiaame *AVR* matavimų regione – apskritimo formos regionas nutolęs nuo *OD* centro nuo 1,5 iki 3 optinio disko spindulių r_{OD} atstumu (Knudtson et al., 2003). Santykis skaičiuojamas atskirai viršutinei ir apatinei dalims optinio disko centro atžvilgiu. Matuojamos dvi pagrindinės (didžiausios) kraujagyslės – arterija ir vena. Taip pat yra kitų šio santykio apskaičiavimo metodų: kai matuojama didesniame regione, kai matuojama daugiau kraujagyslių porų ir t. t. (žr. Sun et al., 2009, Niemeijer et al., 2011). Periodinis šio parametro vertinimas padeda ne tik tiksliau įvertinti ligos eigą, bet ir laiku išvengti ligos sukeltų padarinių.

Matavimai ir kiti akies dugno analizės procesai užima labai daug oftalmologų laiko, o kartais specialistai negali skirti daug laiko vienam pacientui. Jiems padeda kompiuterizuotos sistemos, leidžiančios atlikti didžiąją dalį analizės ir veikiančios kaip patiriamosios ar progreso stebėjimo sistemos (žr. Li et al., 2014, Bankhead et al., 2012). Kuriant tokias sistemas, reikia atsižvelgti į daug specifinių situacijų. Pavyzdžiui, kai ekspertai atlieka matavimus, matavimų vieta yra pasirenkama labai skirtingai kiekvienam iš paveiksluokų – svarbiausias vietos pasirinkimo veiksnys yra sąlygos kuo tiksliau ir patogiau atlikti matavimus. Kai matavimus automatiškai atlieka kompiuteris, matavimų vieta parenkama labai konkrečiai, tačiau daugeliu iš atvejų ši vieta nėra pati tinkamiausia matavimams atlikti. Taip pat vietai parinkti dažnai taikomi iš daugelio etapų sudaryti vietos parinkimo metodai, kuriuose etapai neretai yra priklausomi vieni nuo kitų ir maža klaida viename iš etapų turi įtakos kitiems etapams. Automatinės sistemos dažnai neatpažįsta nei vaizdo kokybės, nei netgi ar pacientas serga, ar ne. Taip pat daugeliu iš atvejų (Muramatsu et al., 2011), (Bankhead et al., 2012) kompiuterizuotos sistemos yra taikomos specifinėmis techninėmis priemonėmis gautiems vaizdams ar specialioms vaizdų duomenų bazėms. Taikomos naujiems vaizdams šios sistemos turi būti pertvarkomos, kad atitiktų naujus reikalavimus. Yra net ir tokių sistemų, kurios vardan vienodo metodo veikimo


praranda dalį vaizdinės informacijos, kai sumažinama vaizdų rezoliucija (Ravishankar et al., 2009).

Sumažintos vaizdo raiškos problema kyla dėl to, kad beveik visi metodai viename ar kitame analizės etape naudoja parametrus, kurių parinkimas priklauso nuo atitinkamo gauto vaizdo raiškos ir kameros matymo lauko. Naujiems vaizdams, ypač gautiems su kitu įrenginiu, šie parametrai turi būti keičiami, kad veiktų atitinkamo metodo dalys. Skirtingos raiškos problema vaizduojama 6 pav.



6 pav. Skirtinga įranga gauti skirtingos raiškos vaizdai.

Daugelis akies dugno analizės metodų yra testuojami tik su labai aukštos kokybės vaizdais. Tačiau tam tikrose situacijose yra sunku gauti labai aukštos kokybės vaizdų arba pakartotinį vaizdą, jei gautas vaizdas nėra labai aukštos kokybės. Vaizdų kokybei taip pat turi įtakos ir ligos sukeltos anomalijos. Dėl šių situacijų kyla reikalavimas, kad automatinės analizės sistemos veiktų ir su žemesnės kokybės vaizdais.



7 pav. Probleminiai akies dugno vaizdai.

Kaip iliustruojama 7 pav., tam tikros problemos daro įtaką klaidoms automatinėje vaizdų analizėje. Šiame paveiksle gauti sugadinti dėl operatoriaus klaidos, dėl ligos poveikio ar dėl netinkamo apšvietimo vaizdai.

Norint įvertinti *AVR*, turi būti nustatomos ir suklasifikuojamos pagrindinės kraujagyslės. Tam gali būti taikomi šie etapai: pvz., *OD* nustatymas yra būtinas, kad matavimai būtų atliekami specialioje vietoje. Taip pat turi būti parenkamos vietos, kuriose atliekami matavimai.

OD nustatymas yra labai reikšmingas daugelyje iš akies dugno analizės etapų (Buteikienė et al., 2012). Kaip minėta anksčiau, *OD* naudojamas siekiant parinkti vietas, kuriose atliekami matavimai, reikalingi *AVR* apskaičiuoti. *OD* taip pat svarbus kraujagyslių trasavimo metoduose, akies dugno analizėje, kai *OD* analizuojamas ligų diagnozėje (pvz., *OD* ekskavacijos vertinimas), ir kitais atvejais. Pagrindinės priežastys, lemiančios netikslų *OD* nustatymą, yra netolygus vaizdo apšvietimas, ligos paveikti akies dugno pokyčiai, kraujagyslių sukeliamas vaizdo triukšmas *OD* viduje ir kt. Įvertinti *AVR* ir nustatyti *OD* taikomas dviejų lygių *OD* nustatymo metodas, detaliau aprašytas 4.1 skyriuje.

Siekiant įvertinti *AVR* parametą, būtina atlikti kraujagyslių matavimus. Dažnai matavimai yra atliekami naudojant išskirtą kraujagyslių medį. Šiuo principu atliekami matavimai gali būti nepatikimi dėl galimų klaidų išskirtame medyje. Dažnai medžio išskyrimo metodų paskirtis yra ne tikslus, o tik apytikslis kraujagyslių išskyrimas, kad išskirtas kraujagyslių medis būtų naudotinas kituose etapuose. Norint atlikti teisingesnius kraujagyslių matavimus, tikslinga yra taikyti papildomus tikslesnius metodus. Galima naudoti kraujagyslės profilio analize paremtus pločio matavimus. Profilio analizė yra dažnas analizės būdas (žr. Li et al., 2003, Bankhead et al., 2012).

Kraujagyslių pločio matavimų metodas pateiktas (Stabingis et al., 2017). Profilio informacija neretai gaunama Bresenghamo algoritmu, šis informaciją gauna greitai, tačiau gautos informacijos taškai tam tikrose situacijose gali būti pasiskirstę netolygiai. Šiai problemai spręsti gali būti naudojamos erdvinės funkcijos, nes jomis gaunama tikslesnė profilio informacija.

Akies dugno anatominių struktūrų tyrimas gali būti labai svarbus diagnozuojant tokias ligas, kaip arterinė hipertenzija, diabetinė retinopatija, amžinė makulos degeneracija ir glaukoma (Kanski, 2007). Akies dugnas susideda iš įvairių anatominių struktūrų, kurios gali padėti diagnozuoti besivystančias ligas. Pvz., pokyčiai makuloje rodo amžiaus paveiktą makulos degeneraciją (Kanagasingam et al., 2014). Optinis diskas ir ekskavacija yra tiriami glaukoms nustatyti (Bock et al., 2010), (Buteikienė et al., 2012), (Treigys et al., 2008). Kraujagyslių struktūrų tyrimas yra svarbus ligų, susijusių su kraujo spaudimu, prognozei: choroidinei neovaskuliarizacijai, hipertenzijai, arteriosklerozei ar insultui (Odstrcilik et al., 2013), (Fraz et al., 2012). Kraujagyslių forma ir vingiuotumas, ekskacijos, kraujosruvos, mikroaneurizmai ir dugno tekstūra – ypatybės, leidžiančios diagnozuoti diabetinę retinopatiją.

Svarbiausi yra tokie akies dugno pokyčiai, kurie įgalina apsaugoti nuo ne akių ligų progresavimo. Sprendimai apie besivystančias ligas gali būti priimami remiantis venų ir arterijų santykio matavimais prieš ir po fizinio krūvio (žr. Morgan et al., 2007). Dar daugiau, venų ir arterijų santykis gali būti veikiamas ne vien fizinės, bet ir psichinės tiriamojo būklės. Automatizuoti santykio matavimus gana sudėtinga, nes arterijas ir venas yra labai sunku atskirti (Mirsharifa et al., 2013), (Kondermann et al., 2007), (Li et al., 2014). Santykio matavimus atlikti taip pat sudėtinga ir dėl to, kad santykio pokyčiai atsiranda mikro lygmenyje. Yra nemažai pasiūlytų arterijų ir venų segmentavimo metodų, tačiau labai reikšmingų rezultatų nėra dėl pažangiausių metodų ribotumo ir naudojamos techninės įrangos. Rezultatams daro įtaką prastas segmentavimas, kai kraujagyslėse matomas vidinis šviesos atspindys. Taip pat įtaką daro prastas segmentavimas išsišakojimuose, susikirtimuose ir persidengimuose. Kraujagyslės, kurios yra arti viena kitos, gali būti sujungtos į vieną, o plonos kraujagyslės gali būti praleistos. Kai kuriose vietose kraujagyslės gali būti klaidingai suklasifikuotos. Tai ypač būdinga regione šalia optinio disko (*OD*) kraštų arba patologiniuose akies dugno regionuose (Nguyen et al., 2013).

Klasifikavimo problema vis dar labai svarbi medicininių vaizdų analizėje (žr. Miri et al., 2017, Renukalatha et al., 2018, Morkunas et al., 2018). Akies dugno kraujagyslėms klasifikuoti taikoma daug skirtingų metodų (žr. Miri et

al., 2017, Dashtbozorg et al., 2014, Sun et al., 2009, Niemeijer et al., 2011, Treigys et al., 2008). Jei siekiama klasifikavimą atlikti automatiškai ir su skirtingo tipo vaizdais, tinkamesni taikyti klasifikavimo be mokymo metodai. Klasifikavimo su mokymu metodai yra tikslesni, tačiau jie turi būti priderinami prie skirtingo tipo vaizdų. Kartais ir ta pačia įranga gautiems vaizdams negali būti taikomas jau apmokytas metodas dėl vaizdo triukšmingumo, apšvietimo ar kitų su vaizdų kokybe susijusių problemų. Medicininių vaizdų analizės metodai pasižymi įvairiomis problemomis, susijusiomis su vaizdų kokybe (žr. Prasath, 2017). Akių analizę veikia skirtingas ar netolygus vaizdo apšvietimas, mažinantis daugelio taikomų metodų tikslumą ir patikimumą, jei testuojant metodus į tai neatsižvelgiama.

Akies dugno kraujagyslėms klasifikuoti yra naudojama daug skirtingų požymių. Dažniausi iš jų gaunami iš vaizdų RGB, HSI, pilkos spalvų informacijos naudojant statistines funkcijas, tekstūrų ypatybes ir kt. (žr. Renukalatha et al., 2018, Muramatsu et al., 2011, Stabingis et al., 2016). Tokio tipo požymiai yra dažni daugeliui kitų vaizdų analizės problemoms spręsti.

Atsiradus galimybėms, giliojo mokymosi metodai pradėti taikyti ir akies dugno vaizdų analizėje įvairiose srityse (Almotiri et al., 2018). Daugelio iš požymių automatinis išskyrimas taikant CNN metodą pasiūlytas straipsnyje (Tan et al., 2017), kuriame siūlomas metodas automatiškai suranda eksudacijas, kraujosruvas ir mikroaneurizmas. Straipsnyje (Adem, 2018) taikytas Hofo apskritimų radimu paremtas galimų eksudacijų radimo metodas, kuris identifikuoja eksudacijas CNN metodu. Straipsnyje (Alghamdi et al., 2016) CNN metodas taikomas automatiškai įvertinti akies dugno optinio disko pakitimams. Kraujagyslių išskyrimas taikant CNN metodą nagrinėtas straipsniuose (Melinscak et al., 2015), (Liskowski et al., 2016). Straipsnyje (Triwijoyo et al., 2017) CNN metodas taikomas tiesiogiai hipertenzinei retinopatijai nustatyti, kai konvoliucinis neuroninis tinklas pritaikomas visam vaizdui, o ne atskiriems ligos požymiams išskirti. Straipsnyje (Gargeya et al., 2017) CNN metodas taikomas tiesiogiai diabetinei retinopatijai nustatyti. Visi minėti konvoliucinių neuroninių tinklų taikymo akių analizėje atvejai turi labai didelį klasifikavimo tikslumą, todėl akies dugno vaizdams būdingų dėšningumų nustatymas gali būti naudingas ir giliojo mokymosi metodams vystyti.

2.4.1. Arterijų ir venų klasifikavimo metodai

Toliau apžvelgiama keletas arterijų ir venų klasifikavimo akies dugno vaizduose metodų.

Straipsnyje (Muramatsu et al., 2011) siūlomas metodas yra skirtas specialiai AVR įvertinti. Šis metodas susideda iš šių žingsnių. Pirmiausia, akies dugno vaizdui taikomas kraujagyslių segmentavimo metodas. Segmentavimas atliekamas su I_G kanalu ir susideda iš „top-hat“ transformacijos, „dvigubo žiedo“ filtro ir slenksčio operacijų. Iš kraujagyslių tinklo išskiriami centrinės linijos taškai. Atsižvelgiant į kraujagyslių susikirtimo ir išsišakojimo taškus, kraujagyslių medis suskaidomas į atskiras kraujagyslių atkarpas. Kraujagyslės, kurių plotis mažesnis už 3 taškus, pašalinamos iš tolesnių skaičiavimų. OD nustatyti taikomi slenksčio operatorius ir elipsės priderinimo metodai. Ilgoji elipsės ašis laikoma OD diametru, nustatant AVR matavimų sritį. Kraujagyslėms segmentuoti ir OD nustatyti naudojami parametrai yra priderinti prie specialios vaizdo raiškos. Klasifikuoti naudojami kraujagyslių centrinės linijos taškai iš AVR matavimų. Kiekvienam centrinės linijos taškui gaunami penki požymiai, kurie toliau naudojami tam taškui klasifikuoti. Šie požymiai – tai RGB reikšmės, atitinkančios tuos taškus, ir kontrasto reikšmės tuose taškuose iš I_R ir I_G kanalų. Kontrasto reikšmės apskaičiuojamos iš atitinkamo kanalo išvedant reikšmių vidurkį 5×5 dydžio regione aplink tašką kraujagyslės viduje ir išvedant reikšmių vidurkį 10×10 dydžio regione aplink tašką kraujagyslės išorėje. Išvedus šiuos dviejų regionų vidurkius, kontrastu laikomas jų skirtumas. Kiekvienas centrinis kraujagyslės taškas patenka į arterijų arba venų klasę taikant LDA metodą. Kraujagyslės atkarpai priskiriama klasė, prie kurios priskiriama daugiausiai tos atkarpos centrinės linijos taškų. AVR matuojamas su didžiosiomis kraujagyslėmis. Kraujagyslių matavimai atliekami remiantis segmentavimo metu gauto kraujagyslių tinklo informacija, ir išvedant vidurkį išilgai kraujagyslės atkarpos. Metodas yra testuotas su DRIVE vaizdų baze. Norint pritaikyti šį metodą kitoms vaizdų bazėms, reikia sumažinti vaizdus iki DRIVE vaizdų dydžio ir jei vaizdai skiriasi savo apšvietimu, spalvų kiekio santykiu skirtinguose kanaluose ar kitomis ypatybėmis, gali reikėti iš naujo priderinti LDA klasifikatorių naujo tipo vaizdams. Kadangi DRIVE vaizdų bazėje esantys vaizdai yra gana tolygiai apšviesti ir mažai triukšmingi, neaišku, kaip šis metodas veiktų su netolygiai apšviestais ar didesni triukšmą turinčiais vaizdais.

Straipsnyje (Mirsharifa et al., 2013) aprašytas metodas susideda iš šių žingsnių: vaizdo gerinimo, kraujagyslių segmentavimo, ploninimo, požymių išskyrimo, arterijų ir venų klasifikavimo ir papildomo apdoravimo. Vaizdui gerinti taikyti histogramų priderinimo, keletas skirtingų histogramų išlyginimo ir daugiasluoksnio „retinex“ metodai. Kraujagyslėms segmentuoti

taikytas (Soares et al., 2006) metodas, paremtas Gabor vilnelių metodu. Iš tolesnių tyrimų pašalintos kraujagyslės, kurių plotis mažesnis už 3 taškus. Kraujagyslės suskirstytos į mažesnius segmentus, ir kiekvienam segmentui gauta daug vaizdų analizėje įprastai naudojamų požymių. Požymiai gauti iš RGB, HSL ir LAB spalvų kanalų ir iš statistikų, gautų pagal šių kanalų informaciją. Iš visų gautų požymių atrinkti aštuoni didžiausiu diskriminuojamumu pasižymintys požymiai. Šiuo metodu kraujagyslėms klasifikuoti taikytas LDA klasifikavimo metodas. Po klasifikavimo dalis kraujagyslių esti nesusietos su bendru kraujagyslių medžiu, todėl joms perklasifikuoti remtasi žiniomis apie kraujagyslių struktūrinės ypatybės. Šiuo metodu buvo klasifikuojamos visos akies dugno vaizdo kraujagyslės, taip pat buvo klasifikuojamos tik *AVR* matavimų srities kraujagyslės. *AVR* matavimų sričiai nustatyti kiekviename vaizde *OD* buvo pažymimas rankiniu būdu. Metodo tyrimams naudota *DRIVE* vaizdų bazė ir pačių metodo autorių vaizdų bazė „Khatam“. Kadangi autorių naudojamose vaizdų bazėse vaizdai yra didesnės raiškos, jie sumažinami keturis kartus, kad atitiktų *DRIVE* bazės vaizdų dydį. Klasifikuoti taikomas tas pats LDA modelis, kuris pritaikytas *DRIVE* bazės vaizdams. Klasifikavimo tikslumas *AVR* srityje su nauja vaizdų baze yra dviem procentais mažesnis lyginant su *DRIVE* bazės rezultatais.

Metode, publikuotame straipsnyje (Niemeijer et al., 2011), yra naudojami šie žingsniai: pirminis apdorojimas, kraujagyslių segmentavimas ir kraujagyslių centrinės linijos išskyrimas, *OD* nustatymas, kraujagyslių pločio matavimai, kraujagyslių klasifikavimas ir *AVR* įvertinimas. Pirminis apdorojimas susideda iš akies dugno vaizdo srities išskyrimo ir Gauso filtro pritaikymo. Kraujagyslėms segmentuoti taikomas klasifikavimo metodas. Šis etapas buvo kuriamas pagal vaizdus iš *DRIVE* vaizdų bazės, tad didesni vaizdai yra sumažinami iki *DRIVE* vaizdų dydžio. Taškų klasifikavimo metu sukuriamas kraujagyslių tikėtino žemėlapis, kuriam atlikus slenksčio operaciją, gaunama kraujagyslių struktūra. Šiame etape taip pat naudotas „tubogganing“ įrankis iš straipsnio (Fairfield, 1990). Paskui kraujagyslių struktūra yra suploninama. *OD* centrui nustatyti taikytas pozicijos regresijos su mokymu metodas iš (Niemeijer et al., 2009) straipsnio. Kadangi vaizdai sumažinami iki standartinio dydžio, pritaikytas fiksuoto dydžio *OD* diametras, kuris toliau naudojamas *AVR* matavimų sričiai išskirti. Kraujagyslių matavimai atlikti pagal segmentavimo metu išskirtą kraujagyslių struktūrą. Matavimai atlikti matuojamos kraujagyslės centro linijai statmenu kampu. Arterijų ir venų klasifikavimas atliktas LDA metodu su 27-iais skirtingais požymiais. Požymiai gauti iš skirtingų vaizdo kanalų skirtingomis statistikomis. Statistika buvo taikoma tiek kraujagyslės dalies centrinei

linijai, tiek ir visai kraujagyslės daliai. Kraujagyslių klasifikavimo metu galutinė klasė nebuvo priskirta, buvo sukurtas tik klasių tikėtinumo žemėlapis. Galutinė kraujagyslių klasės žymė priskiriama AVR įvertinimo etapo metu. Šio etapo metu kraujagyslės buvo klasifikuojamos į arterijas ir venas, remiantis išankstinėmis žiniomis apie arterijų ir venų struktūros ypatybes, o suklasifikuotų kraujagyslių poros toliau buvo naudotos AVR įvertinti. Šis metodas testuotas DRIVE ir su INSPIRE-AVR vaizdų bazėmis. Pastaroji pirmą kartą pristatyta straipsnyje (Niemeijer et al., 2011). LDA metodo veikimas gali būti lemiamas konkrečios vaizdų bazės, su kuria priderinami šio metodo parametrai. Taip pat taikant metodą mažinami vaizdai ir taip prarandama dalis informacijos.

Metodas, pateiktas straipsnyje (Dashtbozorg et al., 2014), kraujagyslėms klasifikuoti remiasi grafų analize. Analizei skirti grafai yra suformuojami iš išskirto kraujagyslių medžio. Kraujagyslėms segmentuoti taikomas metodas aprašytas (Mendonca et al., 2013) straipsnyje. Iš kraujagyslių išskirtų kraujagyslių centro linijų struktūra naudojama grafui sukonstruoti. Grafo struktūra modifikuojama pagal specialų algoritmą ir pašalinamos dažnai pasitaikančios grafų klaidos. Grafo analizė svarbi pirminiam mazgų klasifikavimui. Kitu žingsniu išskiriama 19 skirtingų požymių, pagal kuriuos klasifikuojamos kraujagyslės LDA metodu. Požymiai gaunami iš skirtingų vaizdo kanalų reikšmių ir jų statistikų. Metodas pritaikytas visam kraujagyslių medžiui klasifikuoti ir tik AVR matavimų srityje esančioms kraujagyslėms klasifikuoti. Metodas tikrintas su DRIVE ir INSPIRE-AVR vaizdų bazėmis. Čia grafų analizė atitinka struktūrinės kraujagyslių informacijos įterpimą į kraujagyslių analizę. Grafų analizė yra kaip papildoma tikslinimo priemonė, padedanti atskirti dviejų skirtingo tipo kraujagyslių struktūras, tačiau pagrindinis klasifikavimas atliekamas LDA metodu, tad metodas priklauso nuo vaizdų imties, su kuria buvo apmokytas. Taip pat sukonstruoto grafo kokybė tiesiogiai priklauso nuo kraujagyslių tinklo išskyrimo kokybės. Klaidos šiame etape lemia klaidas grafo analizėje, o nuo grafo analizės tikslumo priklauso ir klasifikavimo tikslumas.

2.4.2. Akies dugno vaizdų bazės

Akies dugno analizės metodai pradėti kurti nuo pirmųjų kamerų atsiradimo. Metodams pademonstruoti ir lyginti pradėtos kurti akies dugno vaizdų duomenų bazės. Toliau pateikiama keletas iš populiariausių akies dugno duomenų bazių sąrašas ir trumpi aprašymai.

Messidor duomenų bazėje yra 1.200 akies dugno spalvotų vaizdų (Decencièere et al., 2014). Šie vaizdai gauti iš trijų oftalmologų departamentų

spalvotomis 3CCD kameromis Topcon TRC NW6 su 45° matymo kampu. Gauti vaizdai turi 8 bitus kiekvienai spalvai ir 1440 × 960, 2240 × 1488 arba 2304 × 1536 taškų skiriamąją gebą. Su vaizdais pateikiamos ir diagnozės: diabetinės retinopatijos stadija ir makulos edemos rizika.

Messidor-2 yra išplėtotą pagrindinė Messidor duomenų bazė, skirta diabeto retinopatijai (Decencière et al., 2014). Joje yra 1.748 akies dugno vaizdai. Vaizdai taip pat gauti spalvotomis Topcon TRC NW6 kameromis su 45° matymo kampu.

Origa-650 (angl. *Online Retinal Fundus Image Dataset for Glaucoma Analysis and Research*) Internetinė akies dugno duomenų bazė, skirta glaukomos analizei ir tyrimams (Zhang et al., 2010). Joje yra 650 vaizdų, gautų SiMES (Singapore Malay Eye Study) tyrimų metu. SiMES vykdo Singapūro akių tyrimų institutas (SERI). Vaizdai yra sužymėti ekspertų. Duomenų bazėje yra 168 glaukoma sergančių pacientų ir 482 glaukoma nesergančių pacientų vaizdai.

DRIVE (Staal et al., 2004) (angl. *Digital Retinal Images for Vessel Extraction*) – skaitmeniniai akies dugno vaizdai kraujagyslėms išskirti. Vaizdai gauti per diabetinės retinopatijos stebėjimo programą Olandijoje. Šiame tyrime dalyvavo 400 diabetu sergančių asmenų. 40 vaizdų parinkta atsitiktinai, iš jų 33 neturi jokių diabeto retinopatijos požymių, o 7 turi nedidelių ankstyvos diabeto retinopatijos požymių. Vaizdai gauti Canon CR5, 3CCD akies dugno kamera su 45° stebėjimo lauku. Vaizdų raiška yra labai maža, tik 565 × 584 taškų. Tačiau tai yra viena iš populiariausių duomenų bazių, pasirenkamų akies dugno analizėje.

DIARETDB0 (angl. *The Standard Diabetic Retinopathy Database Calibration level 0*) – standartinė diabeto retinopatijos kalibravimo duomenų bazė, lygis 0 (Kauppi et al., 2013). Duomenų bazėje yra 130 spalvotų akies dugno vaizdų, iš kurių 20 yra normalūs, o 110 turi diabeto retinopatijos ženklų. Vaizdai gauti su 50° matymo kampo akies dugno kamera, kurios nustatymai nėra aiškūs.

DIARETDB1 (angl. *The Standard Diabetic Retinopathy Database Calibration level 1*) – standartinė diabeto retinopatijos kalibravimo duomenų bazė, lygis 1 (Kauppi et al., 2013). Duomenų bazėje yra 89 spalvotų akies dugno vaizdų, iš kurių 5 yra normalūs, o 84 turi nežymių diabeto retinopatijos ženklų. Vaizdai gauti su 50° matymo kampo akies dugno kamera, kurios nustatymai nėra aiškūs.

STARE (angl. *Structured Analysis of the Retina*) – struktūrizuota ragenos analizė (Hoover et al., 2000). Projektas pradėtas dar 1975 metais Kalifornijos

universitete. Bazėje yra 400 vaizdų su kiekvienam vaizdai atskirais diagnozės kodais ir diagnoze.

INSPIRE-AVR (Niemeijer et al., 2011) (angl. *Iowa Normative Set for Processing Images of the Retina – Artery-Vein Ratio*) Iowa normatyvinė aibė skirta tinklainės vaizdams apdoroti – arterijų ir venų pločių santykiui nustatyti. Joje yra 40 akies dugno vaizdų, kurių raiška – 2394×2048 taškų.

2.5. Skyriaus išvados

Klasifikavimo su mokymu metoduose klasifikuojamas taškas dažnai laikomas nepriklausomu nuo mokymo imties taškų. Be nepriklausomumo prielaidos metoduose galima naudoti ne tik mokymo imties duomenis, bet ir erdvinę informaciją, gaunamą iš šių duomenų. Šios informacijos naudojimas gerina metodų veikimą ir leidžia klasifikavimo metu į modelį įtraukti duomenyse esančią erdvinę koreliaciją bei kitą informaciją.

Nustatyta, kad erdvinė koreliacija klasifikavimo uždaviniuose yra be klasifikuojamo taško nepriklausomumo nuo mokymo imties prielaidos, tad naudojama mokymo imties erdvinė atstumo informacija tikslesniam klasifikavimui atlikti. Naudinga nustatyti ir kitus būdus, atsižvelgiančius į erdvinės priklausomybės įtaką klasifikavimui. Tai gali būti atliekama apskaičiuojant apriorinių klasių tikimybes.

Nagrinėtomis Bajeso diskriminantinėmis funkcijomis su erdvine priklausomybe gaunamas didelis tikslumas. Šiuolaikinėmis technologijomis gaunami ir 3D vaizdai. Šie vaizdai dažnai naudojami medicinoje (KT, MRT). Todėl naudinga apibendrinti erdvine priklausomybe paremtus metodus, kad juos būtų galima taikyti aukštesnės erdvinės dimensijos vaizdams.

Šiuo metu daug dėmesio skiriama giliojo mokymosi metodams. Vaizdų analizėje, ypač vaizdų klasifikavimo srityje, tiriami ir taikomi konvoliuciniai neuroniniai tinklai. Šie, nors ir reikalauja didelių skaičiavimo resursų, duoda labai gerų rezultatų ir generuoja aktualias taikymo galimybes. Konvoliuciniai neuroniniai tinklai naudoja iš skaitmeninių vaizdų gautą erdvinę informaciją apie vaizduose esančius objektus, panaudodami vaizdams apdoroti plačiai taikomus filtrus. Taip pat mokymui skirtos informacijos trūkumo problemos sprendžiamos vaizdų augmentacija, kurioje taip pat taikomi įvairūs vaizdų analizės ir apdorojimo metodai. Šie pavyzdžiai iliustruoja, kad žinios apie skaitmeniniuose vaizduose esančius dėsningumus gali tapti priemone giliojo mokymosi metodams kurti ir vystyti.

Viena iš erdvinės informacijos taikymo vaizdų analizėje sričių yra medicininių vaizdų analizė. Ši analizė yra naudinga priemone, padedanti stebėti ligų progresą, anksti diagnozuoti ligas ir lengviau jas gydyti. Viena iš

svarbių taikymo sričių yra akies dugno vaizdų analizė. Šioje srityje erdvine informacija grįsti statistiniai sprendiniai gali būti panaudoti tikslesnėms ir adaptyvesnėms analizės priemonėms kurti.

Akies dugno vaizdų analizėje ligoms identifikuoti remiamasi keletu požymių. Vienas iš šių požymių yra arterijų ir venų pločių santykis (*AVR*). Šio parametro apskaičiavimas oftalmologui užima daug laiko, o automatizuotos ir visiškai automatinės sistemos palengvintų apskaičiavimą ir ligų diagnozės procesą.

AVR apskaičiavimas yra sudėtingas, nes susideda iš kelių etapų. Svarbu identifikuoti optinį nervų diską, nustatyti *AVR* parametro matavimo zoną, identifikuoti pagrindines kraujagysles, jas suklasifikuoti į venų ir arterijų klases bei atlikti kraujagyslių pločių matavimus. Sudėtingiausios šio proceso dalys yra kraujagyslių klasifikavimas ir pločio matavimai. Pagrindinės priežastys, lemiančios klasifikavimo klaidas, – netolygus vaizdo apšvietimas, kraujagyslių persidengimai ir triukšmas. Kuriant automatinius metodus turi būti atsižvelgiama į šias problemas.

Akies dugno vaizdų analizėje dažnai naudingi įvairūs filtrai ir kitos operacijos. Daugeliui iš šiomis operacijomis sprendžiamų uždavinių reikia parinkti specifinius parametrus. Neretai naudojami metodai atlieka vaizdo suvienodinimo operacijas, jomis siekiama suvienodinti parametrų reikšmes. Taip yra prarandama vaizdo informacija. Kuriant šio pobūdžio metodus, užuot mažinus vaizdus (suvienodinus dydžius), tikslingiau yra perskaičiuoti nuo vaizdo dydžio priklausančius parametrus.

Daugelyje iš *AVR* matavimams skirtų metodų naudojamas LDA klasifikavimas, derinamas prie tam tikros vaizdų bazės. Tačiau kuriant automatinį *AVR* apskaičiavimo metodą, veikiantį su vaizdais iš nežinomos vaizdų bazės, klasifikavimo metodas turėtų būti jos nepriklausomas.

3. ERDVINĖ KLASIFIKAVIMO TAISYKLĖ

Šiame skyriuje pateikiamas ir tyrinėjamas klasifikavimo su mokymu metodas SCRD. Metodo naujumas yra tas, kad didinant erdvinės koreliacijos tarp klasifikuojamo objekto ir mokymo imties objektų įtaką sprendiniui, klasifikavimas atliekamas tiksliau.

Šis skyrius susideda iš šių dalių:

- Pateikiamas detalus SCRD metodo aprašymas, veikimo principai ir taikymo galimybės.
- Pateikiamas SCRD metodo algoritmas ir papildomi algoritmai, reikalingi šiam metodui taikyti vaizdų analizėje.
- Atliekamas SCRD metodo eksperimentinis tyrimas. Šio tyrimo rezultatai patvirtina erdvinės priklausomybės naudojimo būtinybę sąlygomis, nustatytomis šio tyrimo metu.
- Tyrimo rezultatai lyginami su kitais klasifikavimo su mokymu metodais. Lyginama su panašaus sudėtingumo statistiniais metodais, o lyginimas skirtas parodyti, nuo kada tikslinga taikyti SCRD metodą.
- Atliekamas erdvėje koreliuoto triukšmo lygmens įtakos tyrimas.
- Pateikiama eksperimento metu gautų klaidų analizė. Nustatomos vaizde esančių objektų dalių klaidingo išskyrimo priežastys ir surastas būdas, kaip tiksliau pateikti vaizde esančio objekto struktūrą parenkant klasifikuojamam objektui tinkamus kaimynus.
- Siūlomi skirtingi kaimynų parinkimo būdai, aprašomi jų algoritmai ir atliekamas šių būdų taikymo tyrimas. Nustatomas tinkamiausias kaimynų parinkimo būdas.
- Pateikiamas apibendrintas SCRD metodas, skirtas klasifikuoti 3D duomenis. Apibendrintas metodas ištirtas eksperimentais.
- Skyriaus gale pateikiamos apibendrintos viso skyriaus išvados.

3.1. Metodo aprašymas

SCRD (angl. *Spatial Classification Rule with Distance*) – erdvinio klasifikavimo taisyklė su atstumu, publikuota straipsnyje (Stabingis et al., 2014). Metodas paremtas įterptąja Bajeso diskriminantine funkcija, priskiriamas klasifikavimo su mokymu metodų grupei ir taikomas erdvinei informacijai klasifikuoti, kai turima mokymo imtis. Metodo pagrindinė ypatybė – klasifikavimo metu sumodeliuojamas duomenyse esantis erdvėje koreliuotas Gauso atsitiktinis laukas (triukšmas) ir gauta lauko informacija naudojama klasifikavimui. Šiuo metu tiriamas metodas dviejų klasių atveju.

SCRD metodo esmė yra tokia. Klasių apriorinės tikimybės dažniausiai apskaičiuojamos pagal mokymo imties elementų, priklausančių atitinkamai klasei, kiekį. Šios tikimybės apskaičiuojamos tik iš kaimyninių stebėjimų informacijos, o šie stebėjimai imami iš mokymo imties remiantis tam tikru kaimynų parinkimo būdu. Galimi įvairūs kaimynų parinkimo būdai. Dažnai tokios apriorinės tikimybės apskaičiuojamos tik pagal skirtingų klasių objektų skaičių. Tačiau kai kurie objektai yra arčiau, o kiti – toliau nuo klasifikuojamo objekto, todėl vertinant apriorines tikimybes turi būti atsižvelgiama į atstumus tarp šių objektų. Kai atsižvelgiama į atstumus iki atrinktos mokymo imties objektų, apriorinės tikimybės apskaičiuojamos tiksliau. Tad klasifikuojant objektus SCRD metodu, pasiekiamas didesnis tikslumas.

Taikant SCRD metodą požymiai yra modeliuojami stacionariu Gauso atsitiktiniu lauku GRF (angl. *Gaussian Random Field*) $\{Z(s): s \in D \subset \mathbb{R}^2\}$, o klasių žymės – Markovo atsitiktiniu lauku MRF (angl. *Markov Random Field*). Toks modeliavimas yra dažnas vaizdų analizėje, o vaizdų analizės kontekste būseną s reiškia vaizdo tašką.

$Z(s)$ stebėjimo marginalinis modelis klasėje Ω_l yra apibrėžiamas kaip $Z(s) = \mu_l + \varepsilon(s)$, kur μ_l yra klasės l vidurkis, o klaidos dėmuo $\varepsilon(s)$ yra generuojamas su stacionarų nulinį vidurkį turinčiu Gauso atsitiktiniu lauku $\{\varepsilon(s): s \in D\}$ ir su kovariacijos funkcija apibrėžtu modeliu $cov\{\varepsilon(s), \varepsilon(u)\} = \sigma^2 r(s - u)$ visiems $s, u \in D$, kur $r(s - u) = r(h)$ yra erdvinės koreliacijos funkcija, o σ^2 – dispersija, atitinkanti modelio skalės parametą. Per eksperimentus taikoma eksponentinė kovariacijos funkcija:

$$C(h) = \sigma^2 \cdot e^{-\frac{h}{\alpha}} \quad (5)$$

kur α yra koreliacijos pločio parametras.

$$r(s - u) = r(h) = e^{-\frac{h}{\alpha}} \quad (6)$$

kur h yra Euklido atstumas tarp s ir u lokacijų.

Tegul $L = \{1, 2\}$ yra žymių aibė. Vaizdo taško $s \in D$, susieto su $Z(s)$, žymė yra atsitiktinis kintamasis $Y(s)$, įgyjantis reikšmes iš aibės L . Tegul $S_n = \{s_i \in D; i = 1, \dots, n\}$ yra mokymo imties aibė. Pažymėkime $Y = (Y(s_1), \dots, Y(s_n))'$ kaip žymių vektorių, o $Z = (Z(s_1), \dots, Z(s_n))'$ – kaip požymių vektorių. Tada mokymo imtis yra matrica $T = (Z, Y)$. Tarkime, kad įvykis $\{T=t\}$ yra ekvivalentus įvykiui $\{Z = z\} \cap \{Y = y\}$, kur t, z ir y yra atitinkamų atsitiktinių vektorių realizacijos.

Tarkime, kad duotiems $Y=y$ modelis yra $Z = X_y\mu + E$, kur X_y yra plano matrica, $\mu' = (\mu_1, \mu_2)$ ir E yra n -matis atsitiktinių klaidų vektorius, o klaidos pasiskirsčiusios pagal Gauso skirstinį $\mathcal{N}_n(0, \sigma^2 R)$. Tarkime, kad reikia klasifikuoti (nustatyti $Y(s_0)$) požymių stebinį $Z_0 = Z(s_0)$, $s_0 \in D$, $s_0 \notin S_n$ pagal duotą mokymo imtį $T=t$. Čia s_0 yra stebėjimo, kurį reikia klasifikuoti, lokacija. $Z_n = (Z(s_i) | s_i \in S_n)$ yra požymių vektorius iš klasifikuojam stebėjimui kaimyninių stebėjimų, susietų pagal tam tikrą kaimynų parinkimo būdą. Pažymėkime kaip r_0 vektorių erdvinę koreliaciją tarp Z_0 ir Z_n . Taip pat pažymėkime kaip R matricą, sudarytą iš erdviųjų koreliacijų tarp Z_n komponentų. R ir r_0 elementai apskaičiuojami pagal formulę (6). Kadangi Z_0 yra koreliuotas su mokymo imtimi, galima naudoti sąlyginį Gauso skirstinį duotiems $T=t$ ($Z=z$, $Y=y$) su vidurkiu μ_{lt}^0 ir dispersija σ_{0t}^2 , apibrėžtais šiomis formulėmis:

$$\begin{aligned}\mu_{lt}^0 &= E(Z_0 | T = t; Y(s_0) = l) = \mu_l(s_0) + \alpha'_0(z_0 - X_y\mu), \\ \sigma_{0t}^2 &= V(Z_0 | T = t; Y(s_0) = l) = \sigma^2 R_{0n},\end{aligned}\tag{7}$$

kur $\alpha'_0 = r'_0 R^{-1}$, $R_{0n} = 1 - r'_0 R^{-1} r_0$ ir $l = 1, 2$.

Darant prielaidą, kad aposteriorinis skirstinys $Y(s_0)$ duotiems $T=t$ priklauso tik nuo $Y=y$ ir nuo N_0 , aposteriorinis skirstinys $Y(s_0)$ yra

$$\pi_l(y) = P(Y(s_0) = l | T = t), l = 1, 2.\tag{8}$$

Tarkime, kad vidurkiai $\{\mu_l(s)\}$ ir disperija σ^2 yra nežinomi ir juos reikia įvertinti remiantis mokymo imtimi T . Tegul $\hat{\mu}$ ir $\hat{\sigma}^2$ yra μ ir σ^2 įvertiniai, remiantis $T=t$. Pažymėkime parametrų vektorių $\Psi' = (\mu, \sigma^2)$ ir šių parametrų įvertinių vektorių $\hat{\Psi}' = (\hat{\mu}, \hat{\sigma}^2)$.

Įterptoji Bajeso diskriminantinė funkcija (PBDF) yra gaunama pakeičiant Bajeso diskriminantinės funkcijos (BDF) parametrus šių parametrų įvertiniais pagal mokymo imtį $T=t$. Tada anksčiau pateiktai klasifikavimo problemai skirta PBDF yra apibrėžiama šia formule:

$$W_t(Z_0; \hat{\Psi}) = \left(Z_0 - \frac{(\hat{\mu}_{1t}^0 + \hat{\mu}_{2t}^0)}{2} \right) \frac{(\hat{\mu}_{1t}^0 - \hat{\mu}_{2t}^0)}{\hat{\sigma}_{0t}^2} + \gamma(y),\tag{9}$$

$$\hat{\mu}_{1t}^0 = \hat{\mu}_1 + \alpha'_0 (z_n - X_y \hat{\mu}),$$

$$\hat{\mu}_{1t}^0 = E(Z_0|T = t; Y(s_0) = 1) = \hat{\mu}_1 + \alpha'_0 \left(z_n - X_y \begin{pmatrix} \hat{\mu}_1 \\ \hat{\mu}_2 \end{pmatrix} \right), \quad (10)$$

$$\hat{\mu}_{2t}^0 = E(Z_0|T = t; Y(s_0) = 2) = \hat{\mu}_2 + \alpha'_0 \left(z_n - X_y \begin{pmatrix} \hat{\mu}_1 \\ \hat{\mu}_2 \end{pmatrix} \right),$$

$$\hat{\mu} = (X'_y R^{-1} X_y)^{-1} X'_y R^{-1} Z = \begin{pmatrix} \hat{\mu}_1 \\ \hat{\mu}_2 \end{pmatrix},$$

$$\hat{\sigma}_{0t}^2 = Var(Z_0|T = t; Y(s_0) = l) = \hat{\sigma}^2 R_{0n}, \quad (11)$$

$$\hat{\sigma}^2 = \frac{(z - X_y \hat{\mu}) R^{-1} (z - X_y \hat{\mu})}{n-2},$$

$$\gamma(y) = \ln(\pi_1(y)/\pi_2(y)). \quad (12)$$

SCR metodas apibrėžia klasifikavimo taisyklę, paremtą aposterioriniu skirstiniu $Y(s_0)$, apibrėžtu


$$\pi_1(y) = \frac{1}{1 + e^{\rho(1 - \frac{2n_1}{n})}}, n_1 = 0, 1, \dots, n, \quad (13)$$

kur $I_0 = \{i: s_i \in N_0 = NN(8), i = 1, \dots, n\}$ ir kur ρ yra klasterizavimo parametru vadinama neneigiama konstanta, o n_1 – skaičius lokacijų iš N_0 su žymėmis, lygiomis 1. Čia $NN(8)$ yra artimiausių kaimynų parinkimo būdas su aštuoniais artimiausiais kaimynais.

Erdvinio klasifikavimo taisyklė SCR D yra paremta šiuo aposterioriniu skirstiniu:

$$\pi_1(y) = \frac{\sum_{i \in I_0} \frac{\delta(y_i=1)}{d(s_i, s_0)}}{\sum_{i \in I_0} \sum_{j=1}^2 \frac{\delta(y_i=j)}{d(s_i, s_0)}} = \frac{\sum_{i \in I_0} \frac{\delta(y_i=1)}{d(s_i, s_0)}}{\sum_{i \in I_0} \frac{1}{d(s_i, s_0)}}, \quad (14)$$

kur $\delta(\cdot)$ yra 0 – 1 indikatoriaus funkcija, o $d(\cdot, \cdot)$ yra Euklido atstumo funkcija tarp lokacijų. Dviejų klasių atveju $\pi_2 = 1 - \pi_1$.



8 pav. Erdvinės situacijos iliustracija.

Remiantis objektų išsidėstymu, iliustruotu 8 pav., taikant SCR metodą klasių žymių tikimybės yra $\pi_1 = \frac{1}{2}$ ir $\pi_2 = \frac{1}{2}$. Tačiau pagal SCRD metodą pirmos klasės apriorinė tikimybė padidėja, kadangi s_1 ir s_2 lokacijos yra arčiau klasifikuojamo taško s_0 už lokacijas s_3 ir s_4 , kurios yra iš antros klasės. Pagal SCRD metodą paveikslėlyje 8 pavaizduotai situacijai π_1 apriorinė tikimybė yra lygi:

$$\pi_1(y) = \frac{\frac{\delta(y_1 = 1)}{1} + \frac{\delta(y_2 = 1)}{1} + \frac{\delta(y_3 = 1)}{2} + \frac{\delta(y_4 = 1)}{2}}{\sum_{i=I_0} \left(\frac{\delta(y_i = 1)}{d(s_i, s_0)} + \frac{\delta(y_i = 2)}{d(s_i, s_0)} \right)} = \quad (15)$$

$$= \frac{2}{\left(\frac{1+0}{1+1}\right) + \left(\frac{1+0}{1+1}\right) + \left(\frac{0+1}{2+2}\right) + \left(\frac{0+1}{2+2}\right)} = \frac{2}{3}.$$

3.2. SCRD metodo algoritmas

Šiame skyriuje pateikiami viso SCRD metodo algoritmo pseudo kodai.

Algoritmas 1. GET_MI – mokymo imties suformavimas

Pateikiama: klasių objektų matricos M_1 ir M_2 , matrica I

Gražinama: mokymo imties matrica MI

```
(1)   $n \leftarrow 1$ 
(2)  Sukurti  $MI[,1..4]$ 
(3)  FOR  $i \leftarrow 1$  TO eilutės( $I$ ) DO
(4)    FOR  $j \leftarrow 1$  TO stulpeliai( $I$ ) DO
(5)      IF  $M_1[i, j] = 1$  OR  $M_2[i, j] = 1$  THEN
(6)         $MI[n, 1] \leftarrow j$ 
(7)         $MI[n, 2] \leftarrow i$ 
(8)         $MI[n, 3] \leftarrow I[i, j]$ 
(9)        IF  $M_1[i, j] = 1$  THEN
(10)          $MI[n, 4] \leftarrow 1$ 
(11)        ELSE
(12)          $MI[n, 4] \leftarrow 2$ 
(13)        END IF
(14)      END IF
(15)    END FOR
(16)  END FOR
(17)  RETURN  $MI$ 
```

Mokymo imties suformavimo algoritme GET_MI naudojamos dvi klasės atitinkančios matricos M_1 ir M_2 . Šiose matricose ties atitinkamos klasės taškais įgyjamos vienetinės, o kitur – nulinės reikšmės. M_1 ir M_2 gaunamos nuskaičius mokymo imties taškus atitinkančius vaizdus, kurie arba sugeneruojami iš pradinio vaizdo parenkant mokymo imties informaciją, arba gali būti parenkami ekspertų, kai metodas taikomas realiai. Pateikiamų matricų dimensijos sutampa su vaizdo matricos I dimensija. Suformuotos mokymo imties matrica MI sudaryta iš keturių stulpelių. Pirmame stulpelyje pateikiamos mokymo imties objektų x koordinatės, antrame – y koordinatės, trečiame pateikiamos vaizdo I reikšmės koordinatėse x ir y , – Z_n , o ketvirtame – klasių žymės – t .

Pateikiama: taškas $s_0(x_0, y_0)$, kaimynų skaičius nn , matrica MI

Gražinama: atrinktų kaimynų matrica MI_{nn}

```
(1)   $n \leftarrow \text{eilutės}(MI)$ 
(2)  FOR  $i \leftarrow 1$  TO  $n$  DO
(3)     $MI_{nn}[i, 1..4] \leftarrow MI[i, \cdot]$ 
(4)     $MI_{nn}[i, 5] \leftarrow \text{DIST}(MI[i, 1..2], s_0)$  // Euklido atstumas
END FOR
(5)  SORT  $MI_{nn}[\cdot, \cdot]$  BY  $MI_{nn}[\cdot, 5]$  // rikiuoja pagal atstumą
(6)  IF  $MI_{nn}[1, 5] = 0$  THEN
(7)    RETURN  $MI_{nn}[2..nn+1, \cdot]$ 
(8)  ELSE
(9)    RETURN  $MI_{nn}[1..nn, \cdot]$ 
END IF
```

Artimiausių kaimynų parinkimo algoritme mokymo imties matrica papildoma nauju stulpeliu, kuriame pateikiamas apskaičiuotas Euklido atstumas nuo klasifikuojamo taško $s_0(x_0, y_0)$ iki kiekvieno iš mokymo imties elementų. Elementai išrikiuojami atstumo didėjimo tvarka. Gražinamas nurodytas skaičius eilučių – nn artimiausių kaimynų. Jei pirmoje eilutėje apskaičiuotas atstumas lygus 0-iui, ši eilutė gražinimo metu praleidžiama, nes klasifikuojamas taškas yra mokymo imtyje.

Pateikiama: matrica MI_{nn}

Gražinama: X_y – plano matrica

```
(1)  FOR  $i \leftarrow 1$  TO  $\text{eilutės}(MI_{nn})$  DO
(2)    IF  $MI_{nn}[i, 4] = 1$  THEN
(3)       $X_y[i, 1] \leftarrow 1$ 
(4)       $X_y[i, 2] \leftarrow 0$ 
(5)    ELSE
(6)       $X_y[i, 1] \leftarrow 0$ 
(7)       $X_y[i, 2] \leftarrow 1$ 
END IF
END FOR
(8)  RETURN  $X_y$ 
```

Algoritmas 4. GET_PI₁ – apriorinės tikimybės apskaičiavimas

Pateikiama: taškas s_0 , matrica MI_{nn}

Gražinama: π_1 – pirmos klasės apriorinė tikimybė

- (1) $a_1 \leftarrow 0$
 - (2) $a_2 \leftarrow 0$
 - (3) **FOR** $i \leftarrow 1$ **TO** eilutės(MI_{nn}) **DO**
 - (4) $h \leftarrow \text{DIST}(MI_{nn}[i, 1..2], s_0) \setminus\setminus$ Euklido atstumas
 - (5) **IF** $MI_{nn}[i, 4] = 1$ **THEN**
 - (6) $a_1 \leftarrow a_1 + 1 / h$
 - END IF**
 - (7) $a_2 \leftarrow a_2 + 1 / h$
 - END FOR**
 - (8) **RETURN** a_1 / a_2
-

Apskaičiuojama pirmos klasės apriorinė tikimybė, priklausanti nuo atstumo iki atrinktų mokymo imties taškų.

Algoritmas 5. GET_R – MI_{nn} koreliacijų matrica

Pateikiama: parametras α , matrica MI_{nn}

Gražinama: R – koreliacijų matrica

- (1) **FOR** $i \leftarrow 1$ **TO** eilutės(MI_{nn}) **DO**
 - (2) **FOR** $j \leftarrow 1$ **TO** stulpeliai(MI_{nn}) **DO**
 - (3) $h \leftarrow \text{DIST}(MI_{nn}[i, 1..2], MI_{nn}[j, 1..2]) \setminus\setminus$ Euklido atstumas
 - (4) $R[i, j] \leftarrow \exp(-h / \alpha)$
 - END FOR**
 - END FOR**
 - (8) **RETURN** R
-

Apskaičiuojama atrinktų mokymo imties taškų koreliacijų matrica. Koreliacijai apskaičiuoti naudojama eksponentinė koreliacinė funkcija.

Algoritmas 6. Klasifikavimas su SCRD

Pateikiama: matricos I, MI , parametras α , kaimynų skaičius nn .

Gražinama: W – suklasifikuotų duomenų matrica

- (1) **FOR** $i \leftarrow 1$ **TO** eilutės(I) **DO**
- (2) **FOR** $j \leftarrow 1$ **TO** stulpeliai(I) **DO**
- (3) $MI_{nn} \leftarrow \text{GET_NN}(j, i, nn, MI) \setminus\setminus$ pagal 2 algoritmą
- (4) $X_y \leftarrow \text{GET_X}_y(MI_{nn}) \setminus\setminus$ pagal 3 algoritmą
- (5) **IF** $\text{sum}(X_y[, 2]) = 0$ **THEN**

```

(6)            $W[i, j] \leftarrow 1$ 
(7)           ELSE IF  $\text{sum}(X_y[\cdot, 1]) = 0$  THEN
(8)            $W[i, j] \leftarrow 0$ 
(9)           ELSE
(10)           $\pi_1 \leftarrow \text{GET\_PI}_1(j, i, MI_m)$  // pagal 4 algoritmą
(11)           $\pi_2 \leftarrow 1 - \pi_1$ 
(12)           $\gamma \leftarrow \ln(\pi_1 / \pi_2)$ 
(13)           $R \leftarrow \text{GET\_R}(\alpha, MI_m)$  // pagal 5 algoritmą
(14)           $r_0 \leftarrow \exp(-MI_m[\cdot, 5] / \alpha)$ 
(15)           $\alpha_0 \leftarrow r_0' R^{-1}$ 
(16)           $R_{0n} \leftarrow 1 - r_0' R^{-1} r_0$ 
(17)           $\hat{\mu}_l \leftarrow (X_y' R^{-1} X_y)^{-1} X_y' R^{-1} I[i, j]$ 
(18)           $\hat{\mu}_{lt}^0 \leftarrow \hat{\mu}_l + \alpha_0 (I[i, j] - X_y \mu)$ 
(19)           $\hat{\sigma}^2 \leftarrow (I[i, j] - X_y \hat{\mu}_l)' R^{-1} (I[i, j] - X_y \hat{\mu}_l) / (nn - 2)$ 
(20)           $\hat{\sigma}_{0t}^2 \leftarrow \hat{\sigma}^2 R_{0n}$ 
(21)           $W_t \leftarrow (I[i, j] - \text{sum}(\hat{\mu}_{lt}^0) / 2) ((\hat{\mu}_{1t}^0 - \hat{\mu}_{2t}^0) / \hat{\sigma}_{0t}^2) + \gamma$ 
(22)          IF  $W_t \geq 0$  THEN
(23)           $W[i, j] \leftarrow 1$ 
(24)          ELSE
(25)           $W[i, j] \leftarrow 0$ 
                END IF
            END IF
        END FOR
    END FOR
(26) RETURN  $W$ 

```

3.3. Metodo veikimo tyrimas


Eksperimento tikslas – įvertinti siūlomo metodo bendrą klasifikavimo tikslumą. Eksperimentui naudojami dirbtinai sugadinti vaizdai. Visi skaičiavimai ir lyginimo vertinimas atliekami statistiniams skaičiavimams skirta programa R (R Core Team, 2018) (Wiesmann et al., 2016).

Per eksperimentą dirbtinai sugadinti vaizdai yra klasifikuojami SCRD metodu ir kitais dažniais metodais, taikomais klasifikavimui su mokymu. Visi metodai testuojami su tais pačiais duomenimis ir su ta pačia mokymo imtimi. Lyginimui pasirenkami metodai: atraminių vektorių klasifikatorius, dirbtiniai neuroniniai tinklai, sprendimų medžiai ir logistinė regresija. Atraminių vektorių klasifikavimo metodo privalumas yra tas, kad galima mokytis iš mažos mokymo imties (Jain et al., 2000). Šis metodas yra taikomas daugelyje sričių (Ng et al., 2007), (Mahdavejad et al., 2018), (Wang et al., 2017).

Mokant neuroninius tinklus iteratyviai atnaujinamos svorių reikšmės. Svoriai nusako hiper-plokštumas ir hiper-regionus požymių erdvėje (McCulloch et al., 1943), (Lippmann, 1987), (Abiodun et al., 2018). Neuroniniais tinklais gaunamas gana geras bendras tikslumas. Sprendimų medžių metodas apmoko daug klasifikavimo medžių, tada kiekvienas medis priskiria klasifikuojamam objektui klasę. Objektui priskiriama ta klasė, kurią pateikia daugiausia medžių (Breiman, 2001), (Fratello et al., 2019).

3.3.1. Eksperimento ruošimas

Šiame eksperimente naudojami 100 skirtingų paveikslukų. Kiekvieno paveiksluko dydis yra 200×200 taškų. Kiekvienas pradinis vaizdas yra sudarytas iš baltos ir juodos spalvų taškų. Visi vaizdai sukurti ne R programos, o R programoje nuskaitomi naudojant *rtiff* paketą (Kort, 2015). Šis paketas skirtas nuskaityti *.tiff* vaizdus ir suformuoti šių vaizdų taškų informaciją atitinkančias skaičių matricas. Nuskaitytų vaizdų juodi taškai įgyja reikšmes, lygias 0, o balti taškai – reikšmes, lygias 1. Visos likusios – pilkos – taškų reikšmės įgyja reikšmes iš intervalo (0; 1). Keletas iš pradinių vaizdų pavaizduoti 9 pav.



9 pav. Keletas eksperimente naudotų pradinių paveikslukų.

Mokymo imtis T yra sugeneruojama pagal kiekvieną iš pradinių vaizdų. Mokymo imtis paimama atsitiktinai iš kiekvienos klasės. Tik apie 0.8 % visų vaizdo taškų yra naudojami kaip mokymo imties taškai. Taigi mokymo imtį sudaro tik apie 300 iš 40.000 taškų. Pirmoji klasė yra parenkama iš baltos spalvos taškų, o antroji – iš juodos spalvos taškų. Atrinktų mokymo imties taškų pasiskirstymas yra proporcingas kiekvienos iš klasių taškų kiekiui vaizde.

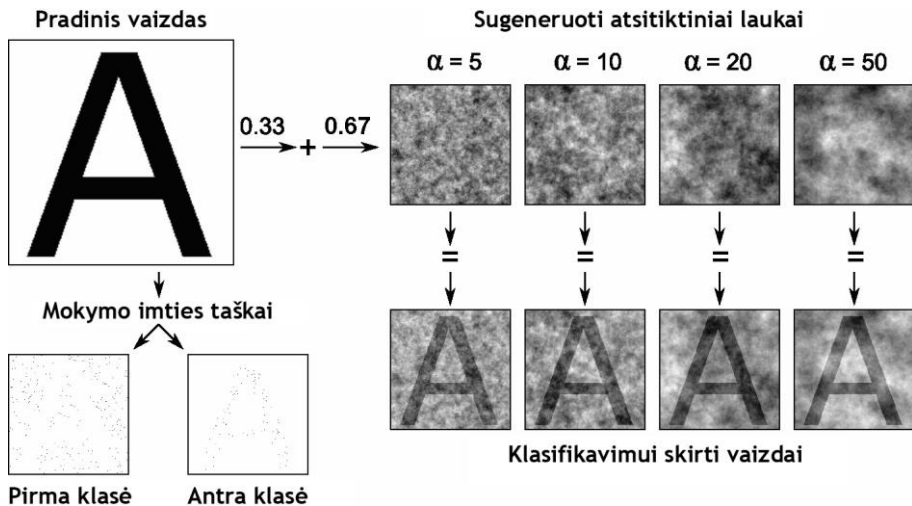
Paskui pradiniai vaizdai sugadinami erdvėje koreliuotu Gauso atsitiktiniu lauku. Laukams generuoti naudojama R programos biblioteka *geoR* (Ribeiro,

2016). Laukams generuoti taikoma izotropinė eksponentinė kovariacijos funkcija (6) ir dispersija, lygi 1. Per šį eksperimentą taip pat tiriama koreliacijos pločio parametro α įtaka klasifikavimo tikslumui. Taigi kiekvienas pradinis vaizdas yra sugadinamas keturiais skirtingais Gauso atsitiktiniais laukais, kur erdvinės koreliacijos pločio parametras α yra lygus 5, 10, 20 ir 50. Šie laukai, sugeneruoti su skirtingomis α parametro reikšmėmis, pavaizduoti 10 pav. Jie generuojami atskirai kiekvienam pradiniam paveikslui.

Kiekvienas sugeneruotas atsitiktinis laukas yra sudarytas iš skaičių matricos, sunormuojamos, kad įgytų reikšmes tarp 0 ir 1. Tada sugeneruoto lauko matrica yra sudedama su pradinio vaizdo reikšmių matrica pagal formulę:

$$I_{\varepsilon} = (1 - p_{\varepsilon}) \cdot I_Z + p_{\varepsilon} \cdot I_{GRF}, \quad (16)$$

čia p_{ε} – triukšmo lygis, įgyjantis reikšmes iš intervalo [0; 1], I_{ε} – naujas paveikslukas su erdvėje koreliuotu triukšmu, I_Z – pradinis paveikslukas, I_{GRF} – erdvinio triukšmo paveikslukas. Per šį eksperimentinį tyrimą triukšmo lygis $p_{\varepsilon} = 0,67$. Šis parametras parinktas toks, kad gautas vaizdas būtų gana sudėtingas analizuojamoms klasifikavimo problemoms. Visa eksperimento ruošimo schema pateikta 10 pav.

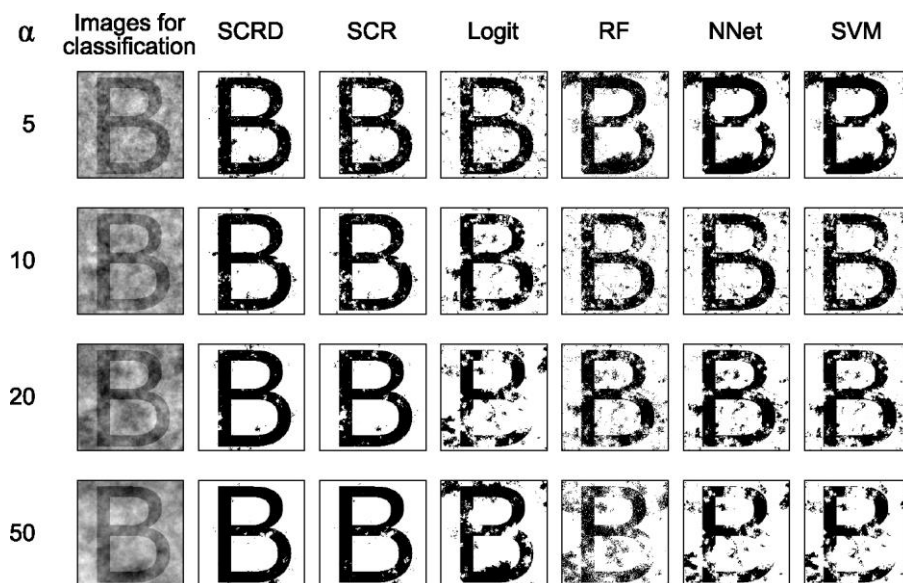


10 pav. Eksperimento ruošimo schema. 100 skirtingų paveikslukų su 4-iomis skirtingomis α reikšmėmis.

Pagal eksperimento ruošimo schemą, pateiktą 10 pav., klasifikavimui parenkama 100 skirtingų vaizdų. Taip gaunama 400 skirtingų vaizdų, nes tirama α įtaka klasifikavimo tikslumui ir eksperimentuojama su 4-iomis skirtingomis α reikšmėmis. Visi 400 vaizdų yra toliau klasifikuojami.

3.3.2. Eksperimento rezultatai

Per eksperimentą visi 400 skirtingų sugadintų vaizdų yra klasifikuojami 6-iais skirtingais klasifikavimo metodais. Klasifikuoti taikomi SCR ir SCDR metodai ir kiti keturi metodai. Pastarieji yra klasifikavimo su mokymu metodai, dažnai taikomi vaizdų taškams klasifikuoti, – Logit, RF, DNT ir SVM. Po klasifikavimo gaunama daug vaizdų. Vieno iš vaizdų su „B“ simboliu visi klasifikavimo rezultatai pateikti 11 pav.



11 pav. Eksperimento su vienu iš paveikslėlių vizualūs rezultatai.

Iš vizualių klasifikavimo rezultatų, pateiktų 11 pav., galima teigti, kad SCR metodas yra pranašesnis už dažnai taikomus klasifikavimo metodus. Naujas metodas SCR D su klasifikavimu susidoroja dar geriau. Taikant abu metodus (SCR ir SCR D) klasifikavimo klaidos gaunamos tose pačiose vietose, tačiau SCR D metodu gaunama mažiau klaidų. Taip pat iš vizualių klasifikavimo rezultatų matosi, kad SCR D metodas pradeda veikti geriau, kai didėja koreliacijos pločio parametro α reikšmės. Dažnai taikomiems metodams ši priklausomybė yra priešinga.

Čia pateikiami vizualūs rezultatai tik vieno pradinio vaizdo atžvilgiu, tačiau kitų vaizdų rezultatų rinkiniai duoda labai panašių rezultatų. Po klasifikavimo visi rezultatų vaizdai analizuoti skaitiškai. Apskaičiuoti vidutinis klasifikavimo tikslumas, klasifikavimo tikslumo standartinis nuokrypis, minimalus ir maksimalus klasifikavimo tikslumas. Rezultatai, gauti su kiekvienu iš taikytų metodų, pateikti lentelėje 1.

Lentelė 1. Bendri klasifikavimo tikslumo rezultatai.

Metodas	SCRD	SCR	Logit	RF	DNT	SVM
Vidurkis	0,984	0,977	0,908	0,888	0,907	0,908
σ	0,009	0,014	0,030	0,037	0,030	0,030
Min	0,946	0,925	0,759	0,731	0,761	0,756
Max	0,999	0,999	0,978	0,965	0,977	0,978

Kaip minėta anksčiau, tiriama erdvinės koreliacijos pločio parametro α įtaka klasifikavimo tikslumui. Bendro klasifikavimo tikslumo didėjant α parametro reikšmei rezultatai pateikti lentelėje 2.

Lentelė 2. Vidutinis ir minimalus klasifikavimo tikslumas pagal α parametą.

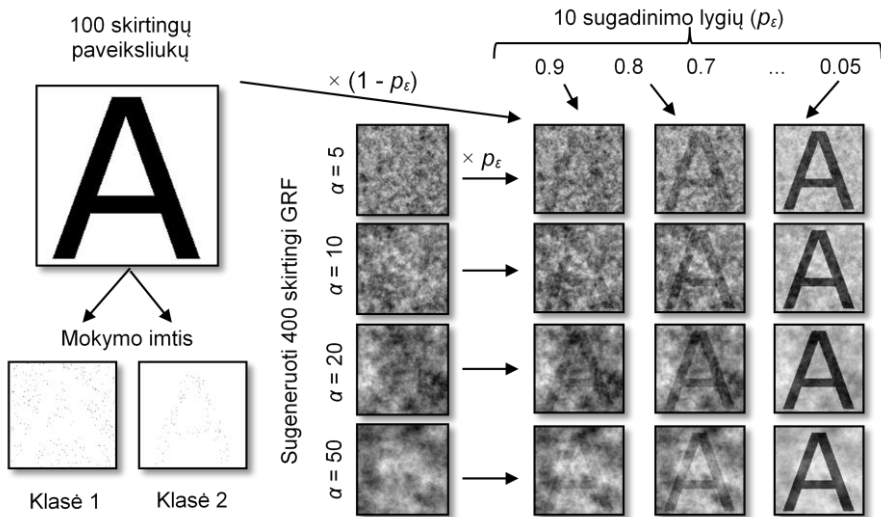
Metodas	SCRD	SCR	Logit	RF	DNT	SVM
α	Vidutinis klasifikavimo tikslumas					
5	0,973	0,962	0,927	0,910	0,926	0,926
10	0,980	0,971	0,915	0,896	0,914	0,915
20	0,988	0,984	0,905	0,882	0,904	0,904
50	0,994	0,993	0,886	0,863	0,886	0,886
α	Mažiausias klasifikavimo tikslumas					
5	0,946	0,925	0,879	0,858	0,878	0,881
10	0,958	0,943	0,863	0,841	0,857	0,859
20	0,972	0,963	0,817	0,753	0,814	0,815
50	0,976	0,972	0,759	0,731	0,761	0,756

Remiantis skaitiniais rezultatais, pateiktais lentelėje 1 ir lentelėje 2, galima teigti, kad papildomas erdvinės priklausomybės įterpimas į įterptąsias Bajeso diskriminantines funkcijas (metodas SCRD metodo SCR atžvilgiu) padidina klasifikavimo tikslumą. Taip pat didėjant erdvinės koreliacijos pločiui SCR ir SCRD metodų klasifikavimo tikslumas didėja, o įprastų klasifikavimo metodų tikslumas mažėja. Šioms išvadoms patikslinti kitame skyriuje atliekamas


platesnis vaizdų sugadinimo įtakos ir erdvinės koreliacijos pločio įtakos tyrimas.

3.4. Triukšmo įtakos tyrimas


Siekiant nustatyti, kiek stipriai sugadintas vaizdas gali būti sėkmingai suklasifikuotas taikant SCR D metodą, atliktas eksperimentinis tyrimas. Eksperimento schema pateikta 12 pav. Skirtingai sugadinti vaizdai klasifikuojami SCR D metodu, SCR metodu ir kitais klasifikuoti taikomais metodais. Iš 100-o pradinių vaizdų sugeneruota mokymo imtis. Pradiniai vaizdai sugadinami GRF laukais. GRF laukai sugeneruoti su keturiomis skirtingomis koreliacijos pločio parametro α reikšmėmis. Vaizdai sugadinami pagal 10 skirtingų sugadinimo lygmenų. Naujas vaizdas, naudojamas klasifikavimui, gaunamas sujungiant pradinį vaizdą su erdvėje koreliuotą triukšmą atitinkančiu vaizdu pagal formulę (16). Klasifikavimui paruošiami 4000 vaizdų. Bendras rezultatų klasifikavimo tikslumas pateikiamas 13 pav. Klasifikavimo tikslumo priklausomybės nuo koreliacijos pločio parametro rezultatai pateikiami 14 pav.



12 pav. Triukšmo įtakos eksperimentinio tyrimo schema.



13 pav. Eksperimento rezultatai. Bendras klasifikavimo tikslumas.




14 pav. Klasifikavimo tikslumo koreliacijos pločio atžvilgiu tyrimo rezultatai.

Remiantis 13 pav., esant triukšmui iki 0,7 visi metodai klasifikuoja labai gerai. Nuo 0,75 triukšmo erdvinę informaciją naudojantys klasifikavimo metodai pradeda įgyti pranašumą. Nuo 0,85 triukšmo SCRD metodas įgyja pranašumą ankstesnio metodo atžvilgiu. Pagal 14 pav. pateiktus grafikus galima matyti, kad didėjant koreliacijos pločiui erdvinę informaciją naudojantys metodai klasifikuoja geriau. Kiti metodai didėjant koreliacijai duomenyse klasifikuoja prasčiau.

3.5. Klasifikuojamo erdvės taško kaimynų parinkimas

Ankstesniuose darbuose buvo naudojama artimiausių kaimynų schema. Klasifikavimo metu kai kurios objektų dalys klaidingai suklasifikuotos, nes tose dalyse nebuvo atitinkamo klasės mokymo imties taškų ir jos buvo apsuptos mokymo imties taškų iš kitos klasės. Ši situacija iliustruojama 15 pav.



15 pav. Probleminė situacija, kai klasifikuojamo taško aplinkoje nėra atitinkamos klasės taškų iš mokymo imties.

Šiai problemai spręsti pasirinkta skirtingų kaimynų parinkimo būdų analizė. Rezultatai publikuoti (Stabingis et al., 2015). Pasiūlyti ir ištirti šie būdai.


$NN(n)$ metodas atrenka n artimiausių kaimynų iš mokymo imties. Šiuo būdu įvairūs skirtingų klasių taškų kiekiai gali būti parinkti. Gali susidaryti situacija, kai visi taškai bus parinkti iš vienos klasės, taip taškas taip pat priskiriamas prie atitinkamos klasės.

$NN_C(n, m_c)$ metodas iš pradžių parenka n artimiausių kaimynų iš mokymo imties, taip pat kaip $NN(n)$ metodas. Jei n_i (parinkti kaimyniniai taškai iš i -osios klasės) yra mažesnis už m_c , taip pat iš mokymo imties parenkama $m_c - n_i$ i -osios klasės artimiausių taškų. Tai atliekama su visomis klasėmis. Šiuo atveju visada parenkama bent po m_c elementų iš kiekvienos klasės, tad kiekvienas klasifikuojamas taškas yra suklasifikuojamas įvertinant visų klasių artimiausių informaciją.

$NN_{R1}(r_t, n)$ metodas parenka kaimynus iš mokymo imties, kur Euklido atstumas tarp mokymo imties taškų ir klasifikuojamo taško yra mažesnis arba lygus spinduliui r_t . Gali atsitikti, kad nė vienas taškas nebus pasirinktas. Jei nepasirenkamas nė vienas taškas, spindulys r_t didinamas tol, kol parenkama n mokymosi imties taškų. Šiuo būdu gali susidaryti $NN(n)$ būdai analogiška situacija, kai visi taškai parenkami iš tos pačios klasės.

$NN_{R2}(r_t, n, m_c)$ būdas iš pradžių parenka kaimynus iš mokymo imties tokiu pat principu kaip $NN_{R1}(r_t, n)$ būdas. Parinkus n kaimynų, spindulys r_t didinamas tol, kol parenkama po m_c objektų iš kiekvienos klasės.

Skirtingi kaimynų parinkimo būdai pavaizduoti 16 pav.



16 pav. Skirtingų kaimynų parinkimo būdų grafinis vaizdavimas.

3.5.1. Kaimynų parinkimo būdų algoritmai.

Toliau pateikiami kaimynų parinkimo būdų tyrime taikyti algoritmai. GET_NN algoritmas jau buvo pateiktas anksčiau (žr. algoritmas 2).

Algoritmas 7. GET_NN_C – nn artimiausių kaimynų, po m_c iš kiekvienos klasės.

Pateikiama: taškas s_0 , kaimynų skaičius nn , m_c , matrica MI

Gražinama: parinktų kaimynų matrica MI_{nn}

- (1) $n \leftarrow MI$ eilučių skaičius
- (2) $i_1 \leftarrow 0$
- (3) $i_2 \leftarrow 0$
- (4) **FOR** $i \leftarrow 1$ **TO** n **DO**
- (5) **IF** $MI[i, 4] = 1$ **THEN**
- (6) $i_1 \leftarrow i_1 + 1$
- (7) $MI_{i_1}[i_1, 1..4] \leftarrow MI[i, \cdot]$
- (8) $MI_{i_1}[i_1, 5] \leftarrow \text{DIST}(MI[i, 1..2], s_0) \parallel$ Euklido atstumas
- (9) **ELSE**
- (10) $i_2 \leftarrow i_2 + 1$


```

(11)       $MI_2[i_2, 1..4] \leftarrow MI[i, \cdot]$ 
(12)       $MI_2[i_2, 5] \leftarrow \text{DIST}(MI[i, 1..2], s_0) \parallel \text{Euklido atstumas}$ 
          END IF
          END FOR
(13) SORT  $MI_1[\cdot, \cdot]$  BY  $MI_1[\cdot, 5]$  // rikiuoja pagal atstumą
(14) SORT  $MI_2[\cdot, \cdot]$  BY  $MI_2[\cdot, 5]$  // rikiuoja pagal atstumą
(15) IF  $MI_1[1, 5] = 0$  THEN
(16)       $MI_1[1...(i_1-1), \cdot] \leftarrow MI_1[2...i_1, \cdot]$ 
(17) ELSE IF  $MI_2[1, 5] = 0$  THEN
(18)       $MI_2[1...(i_2-1), \cdot] \leftarrow MI_2[2...i_2, \cdot]$ 
          END IF
(19)  $i \leftarrow 0$ 
(20) FOR  $i_1 \leftarrow 1$  TO  $m_c$  DO
(21)       $i \leftarrow i + 1$ 
(22)       $MI_m[i, \cdot] \leftarrow MI_1[i_1, \cdot]$ 
(23)       $i \leftarrow i + 1$ 
(24)       $MI_m[i, \cdot] \leftarrow MI_2[i_1, \cdot]$ 
          END FOR
(25)  $i_2 \leftarrow i_1$ 
(26) IF  $nn > 2 * m_c$  THEN
(27)      FOR  $i$  TO  $nn$  DO
(28)          IF  $MI_1[i_1, 5] < MI_2[i_2, 5]$  THEN
(29)               $MI_m[i, \cdot] \leftarrow MI_1[i_1, \cdot]$ 
(30)               $i_1 \leftarrow i_1 + 1$ 
(31)          ELSE
(32)               $MI_m[i, \cdot] \leftarrow MI_2[i_2, \cdot]$ 
(33)               $i_2 \leftarrow i_2 + 1$ 
          END IF
      END FOR
END IF
(34) SORT  $MI_{nn}[\cdot, \cdot]$  BY  $MI_{nn}[\cdot, 5]$  // rikiuoja pagal atstumą
(35) RETURN  $MI_{nn}$ 

```

Algoritmas 8. GET_NN_{R1} – artimiausių kaimynų, nutolusių iki r_t , parinkimas.

Pateikiama: taškas s_0 , atstumas r_t , kaimynų skaičius nn , matrica MI

Gražinama: parinktų kaimynų matrica MI_{nn}

```

(1)   $n \leftarrow MI$  eilučių skaičius
(2)  FOR  $i \leftarrow 1$  TO  $n$  DO
(3)       $MI_r[i, 1..4] \leftarrow MI[i, \cdot]$ 

```

```

(4)    $MI_r[i, 5] \leftarrow \text{DIST}(MI[i, 1..2], s_0)$  // Euklido atstumas
      END FOR
(5)   SORT  $MI_r[\cdot, \cdot]$  BY  $MI_r[\cdot, 5]$  // rikiuoja pagal atstumą
(6)   IF  $MI_r[1, 5] = 0$  THEN
(7)      $MI_r[1...(n-1), \cdot] \leftarrow MI_r[2...n, \cdot]$ 
(8)      $n \leftarrow n - 1$ 
      END IF
(9)    $MI_{nn}[1...nn, \cdot] \leftarrow MI_r[1...nn, \cdot]$ 
(10)  FOR  $i \leftarrow nn+1$  TO  $n$  DO
(11)    IF  $MI_r[i, 5] \leq r_t$  THEN
(12)       $MI_{nn}[i, \cdot] \leftarrow MI_r[i, \cdot]$ 
(13)    ELSE
(14)      STOP LOOP
      END IF
      END FOR
(15)  RETURN  $MI_{nn}$ 

```

Algoritmas 9. GET_NN_{R2} – artimiausių kaimynų, nutolusių iki r_t , parinkimas, būtinai po m_c iš kiekvienos klasės.

Pateikiama: taškas s_0 , atstumas r_t , kaimynų skaičius nn , m_c , matrica MI

Gražinama: parinktų kaimynų matrica MI_{nn}


```

(1)    $n \leftarrow MI$  eilučių skaičius
(2)   FOR  $i \leftarrow 1$  TO  $n$  DO
(3)      $MI_r[i, 1..4] \leftarrow MI[i, \cdot]$ 
(4)      $MI_r[i, 5] \leftarrow \text{DIST}(MI[i, 1..2], s_0)$  // Euklido atstumas
      END FOR
(5)   SORT  $MI_r[\cdot, \cdot]$  BY  $MI_r[\cdot, 5]$  // rikiuoja pagal atstumą
(6)   IF  $MI_r[1, 5] = 0$  THEN
(7)      $MI_r[1...(n-1), \cdot] \leftarrow MI_r[2...n, \cdot]$ 
(8)      $n \leftarrow n - 1$ 
      END IF
(9)    $m_1 \leftarrow 0$ 
(10)   $m_2 \leftarrow 0$ 
(11)   $nn \leftarrow 0$ 
(12)   $i \leftarrow 1$ 
(13)  WHILE  $i \leq n$  AND  $i < nn$  AND  $i < m_1$  AND  $i < m_2$  AND  $MI_r[i, 5] \leq r_t$  DO
(14)     $MI_{nn}[i, \cdot] \leftarrow MI_r[i, \cdot]$ 
      END WHILE
(15)  RETURN  $MI_{nn}$ 

```

3.5.2. Kaimynų parinkimo būdų tyrimas

Kaimynų parinkimo būdams įvertinti atliktas eksperimentinis tyrimas. Eksperimento schema pateikta 17 pav. Eksperimentas atliktas su 100 skirtingų pradinių vaizdų, kurių dydis 200×200 taškų. Iš pradinių vaizdų sugeneruota mokymo imtis. Pradiniai vaizdai sujungti su Gauso atsitiktiniais laukais pagal formulę (16). Pasirinktas stiprus sugadinimas $p_\varepsilon = 0,75$. Iš viso klasifikavimui sugeneruota 700 skirtingų vaizdų.




17 pav. Kaimynysčių schemas įtakos eksperimentinio tyrimo schema.

Atlikto eksperimento klasifikavimo tikslumo rezultatai pateikiami lentelėje 3. Iš šių rezultatų matyti, kad visais panaudotais kaimynų parinkimo būdais gaunami panašūs klasifikavimo rezultatai.

Lentelė 3 Eksperimento rezultatai.

Metodas	$NN(4)$	$NN(8)$	$NN_C(2; 2)$	$NN_C(4; 2)$
Tikslumas	98,36	98,96	98,36	98,6
Metodas	$NN_{R1}(1; 4)$	$NN_{R1}(3; 4)$	$NN_{R2}(1; 4; 1)$	$NN_{R2}(3; 4; 1)$
Tikslumas	98,8	98,88	98,61	98,92

Išanalizavus eksperimento metu gautus rezultatus vizualiai buvo nustatytos situacijos, kuriose kaimynų parinkimo būdas daro įtaką rezultatams. Kelios iš šių situacijų pavaizduotos 18 pav.



18 pav. Kaimynų parinkimo būdų įtakos eksperimento rezultatai.

Nors bendras klasifikavimo tikslumas yra panašus visų kaimynų parinkimo būdų, tačiau vertinant gautus vizualius rezultatus aiškėja NN_C ir NN_{R2} metodų pranašumas situacijose, kai klasifikuojamo taško artimoje aplinkoje nėra atitinkamos klasės mokymo imties taškų.

3.6. Išplėtotas SCRD metodas duomenims 3D erdvėje

Analizuojant ir taikant SCRD metodą būdavo naudojama tik dvimatė (2D) koordinacių sistema. 2D metodo versija gali būti naudojama daugeliui situacijų erdvinėje statistikoje ir vaizdų analizėje: nuotolinio stebėjimo (palydovinių) vaizdų klasifikavimui, medicininių vaizdų analizei ir kt. Medicinoje dažnai dirbama su MRT (magnetinio rezonanso tomografija), KT (kompiuterinės tomografijos) vaizdais. Dažnai tokių vaizdų atskiri sluoksniai analizuojami nepriklausomai vienas nuo kito, o tam tinkamas SCRD metodas tik su 2D koordinacių sistema. Žinant atstumus tarp sluoksnių SCRD metodą galima išplėtoti ir pritaikyti trimatei (3D) koordinacių sistemai. SCRD metodo išplėtojimas pateiktas ir analizuotas straipsnyje (Stabingis, 2016). Čia pateikiamas šis išplėtotas metodas ir eksperimentas, kuriuo parodomas metodo taikymo galimybės.

Pagal SCRD metodą požymiai modeliuojami Gauso atsitiktiniu lauku (GRF). Išplėto metodo, kai siekiama panaudoti tris erdvines dimensijas, atveju GRF lauko stebėjimai modeliuojami: $\{Z(s): s \in D \subset \mathbb{R}^3\}$. Klasių žymės modeliuojamos diskrečiu Markovo atsitiktiniu lauku. s apibudina taško būseną. Anksčiau s buvo aprašoma dviem erdvinėmis koordinatėmis s_x ir s_y . Trimatėje erdvėje prisideda papildoma s_z koordinatė.

Papildoma erdvinė koordinatė keičia Euklido atstumo tarp būsenų s ir u skaičiavimą:

$$h = d(s, u) = \sqrt{(s_x - u_x)^2 + (s_y - u_y)^2 + (s_z - u_z)^2}. \quad (17)$$


Išplėtotas metodas keičia šiuos skaičiavimus: $\pi_1(y)$, $\pi_2(y)$, $\gamma(k)$, $cov\{\varepsilon(s), \varepsilon(u)\}$, $r(h)$ ir R_{0n} .

3.6.1. Eksperimentinis tyrimas

Norint parodyti išplėto SCRD metodo taikymo 3D vaizdams galimybes, atliktas dirbtinis eksperimentas. Sugeneruota 100-as skirtingų trimačių objektų. Kiekvieno sugeneruoto objekto dydis: $50 \times 50 \times 50$ taškų. Trimatis GRF laukas sugeneruotas R programa (R Core Team, 2018) ir paketu RandomFields (Schlather, 2017). GRF laukas sugeneruotas pagal eksponentinę kovariacijos funkciją su koreliacijos pločio parametru $\alpha=20$. Sugeneruotas laukas pridėtas prie pradinio trimačio paveiksliuko su $p_\varepsilon = 0,75$. Gautas paveiksliukas naudojamas klasifikavimui išplėto SCRD metodu.

α ir sugadinimo įtaka tirta darbuose (Stabingis et al., 2014), (Stabingis et al., 2015) dvimatės koordinatinių sistemos atveju. Šio tyrimo metu parametrai yra parinkti taip, kad problema būtų gana sudėtinga šiam uždaviniui spręsti. Su mažesne α reikšme lauko įtaka nebūtų gana pastebima tarp skirtingų paveiksliuko sluoksnių. Mažiau sugadintus vaizdą būtų galima tikėtis labai didelio klasifikavimo tikslumo ir vizualūs rezultatai nebūtų pakankamai informatyvūs.


Mokymo imtis sugeneruota kiekvienam paveiksliukui iš pradinio vaizdo. Mokymo imtis yra mažesnė už 0,8 % visų taškų. Visa eksperimento ruošimo schema pateikta 19 pav.



19 pav. Eksperimento schema. Pagal šią schemą sugeneruota ir suklasifikuota 100 skirtingų objektų.

3.6.2. Tyrimo rezultatai

Atlikus klasifikavimą išplėtotu SCRD metodu gautas vidutinis klasifikavimo tikslumas: 91,5 %. Mažiausias tikslumas – 79,3 %. Didžiausias tikslumas – 96,6 %. Gautas klasifikavimo tikslumas panašus į klasifikavimo tikslumą dvimačių koordinatinių atveju. Klasifikavimo tikslumas apskaičiuojamas pagal formulę $\frac{(n-n_{err})}{n} \times 100$, čia n_{err} – klaidingai suklasifikuotų taškų skaičius.



20 pav. Trimačių vaizdų klasifikavimo tyrimo rezultatai.

Klasifikavimo rezultatai pateikti vizualiai 20 pav. Čia pateikiami vienas po kito einantys keletas skirtingų sluoksnių. Raudona spalva – klaidingai suklasifikuoti pirmos klasės taškai. Žalia spalva – klaidingai suklasifikuoti antros klasės taškai. Iš vizualių rezultatų matyti, kad klaidingas klasifikavimas yra nežymus. Taip pat matyti, kad viename sluoksnyje esančio taško klasifikavimui turi įtakos kitame sluoksnyje esantys mokymo imties taškai.

3.7. Skyriaus išvados

Atlikti didelės apimties klasifikavimo tyrimo eksperimentai, gerai reprezentuojantys panašias praktines klasifikavimo problemas. Per eksperimentus gauti rezultatai rodo, kad papildomos erdvinės informacijos, šiuo atveju erdvės atstumo tarp mokymo imties taškų ir klasifikuojamo taško, įvedimas į apriorinių klasių tikimybių apskaičiavimą padidina klasifikavimo tikslumą.

SCRD metodo klasifikavimo tikslumas yra didesnis už SCR metodo klasifikavimo tikslumą. Per vizualią analizę nustatyta, kad tiek SCR, tiek SCR metodo klasifikavimo klaidų pasitaiko tose pačiose vietose, tačiau SCR metodo klaidingo klasifikavimo plotai yra mažesni.

Dažnai vaizdų analizėje naudojami kiti klasifikavimo su mokymu metodai yra jautrūs erdvėje koreliuotam triukšmui. Per eksperimentus nustatyta, kad šių metodų klasifikavimo tikslumas mažėja didėjant erdvinės koreliacijos pločiui α .

4. AKIES DUGNO KRAUJAGYSLIŲ KLASIFIKAVIMAS

Šiame skyriuje tiriamos statistinių sprendimų panaudojimo akies dugno vaizdų analizei automatizuoti galimybės. Pateikiami metodai, skirti akies dugno vaizdų analizei. Šiuose metoduose naudojama erdvinė informacija, padedanti išspręsti 2.4 skyriuje aptartas su akies dugno vaizdų analize susijusias problemas. Pagrindinė metodų paskirtis yra arterijų ir venų pločių santykio – AVR parametro apskaičiavimas. Šis parametras reikšmingas ligų diagnozėje, nes gali padėti iš anksto diagnozuoti ligas ir įvertinti ligų eigą.

Šis skyrius susideda iš šių dalių:

- Pirmiausia pateikiamas akies dugno vaizdų analizės priemonių tyrimas ir iš jų sukurtas pradinis analizės metodas. Aprašomas šio metodo taikymo eksperimentinis tyrimas. Per šį tyrimą iškeliamos su taikytais metodais susijusios problemos, siekiant automatizuoti akies dugno analizės procesą.
- Atsižvelgiant į iškeltas problemas, sukurtas akies dugno kraujagyslių matavimo metodas (Stabingis et al., 2017). Pateikiamas metodo aprašymas ir automatizavimui aktualūs metodo principai. Šiuo metodu matavimai atliekami analizuojant matuojamos kraujagyslės ir jos aplinkos informaciją. Ši informacija gaunama pagal erdvinio atstumo funkciją, o analizei taikomi statistiniai metodai.
- Pateikiamas sukurto kraujagyslių matavimų metodo tyrimas ir šio metodo taikymo galimybės. Kraujagyslių matavimai lyginami su rankiniu būdu gautais ekspertų matavimais. Automatizuoti matavimai nesiskiria nuo ekspertų atliktų matavimų su 0,95 reikšmingumo lygmeniu.
- Toliau pateikiamas sukurtas visiškai automatinis AVR parametro įvertinimo metodas (Stabingis et al., 2018), daugiausia dėmesio skiriama kraujagyslėms klasifikuoti į arterijas ir venas. Metodas kuriamas atsižvelgiant į universalumo ir adaptyvumo skirtingiems vaizdams reikalavimus.
- Sukurto klasifikavimo metodo ypatumai yra kraujagyslių matavimų metu išskiriami nauji požymiai ir erdvinio atstumu tarp klasifikuojamų kraujagyslių paremtas normalizavimas.
- Pateikiamas klasifikavimo metodo tyrimas su skirtingomis akies dugno vaizdų bazėmis ir lyginimas su panašiais tos pačios paskirties klasifikavimo metodais.

- Papildomai atliekamas ir siūlomo metodo tyrimas taikant klasifikavimo su mokymu metodus. Siekiama parodyti metodų adaptyvumo prie skirtingo tipo duomenų svarbą, kai modeliavimas ir taikymas atliekami su skirtingo tipo vaizdais.
- Skyriaus pabaigoje apibendrinami tyrimų metu gauti rezultatai ir taikymo ypatumai.

Kadangi šiame skyriuje nagrinėjamos akies dugno vaizdų analizės automatizavimo galimybės, ankstesniame skyriuje pasiūlytas ir tyrinėtas SCRD metodas čia nėra taikomas, nes šiam metodui veikti reikalinga tame pačiame vaizde esanti mokymo informacija. Tačiau automatizavimo galimybių tyrimai ir vaizdų dėsningumų išskyrimas gali būti panaudotas ir automatiniam mokymui skirtai informacijai vaizduose išskirti.

4.1. Akių dugno analizės metodikos pagrindai

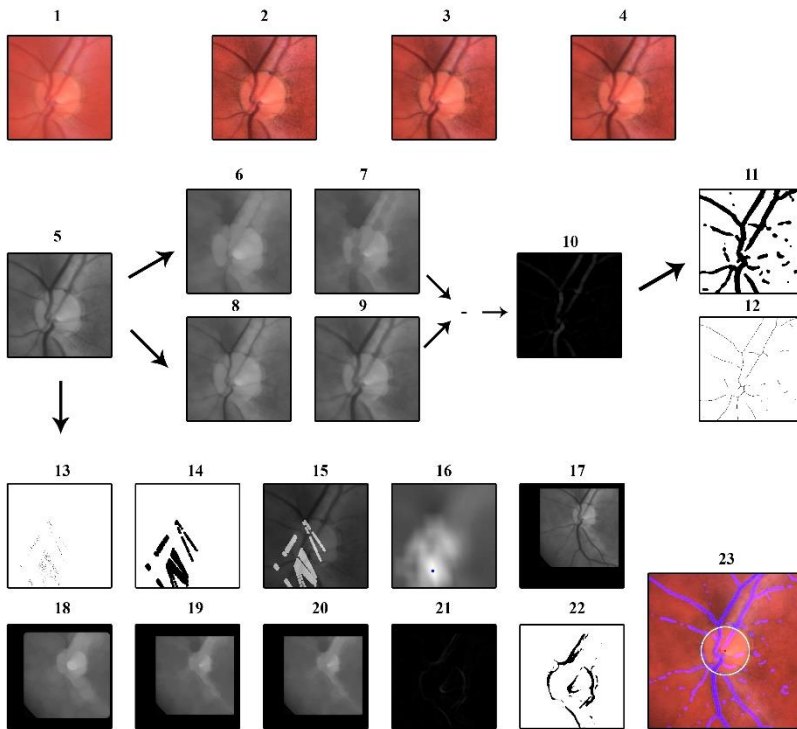
Pateikiamas automatinis arterijų ir venų segmentavimo ir klasifikavimo metodas bei arterijų ir venų diametro santykio (*AVR*) įvertinimas akių dugno vaizduose. Metodui reikia išskirti ir optinio nervų diską, kad *AVR* matavimai galėtų būti atliekami specialioje vietoje. Taip pat atliekamas kraujagyslių identifikavimas pagal šviesumą.

Kuriant metodiką remiamasi dviem darbais (Pachiyappan et al., 2012) ir (Ravishankar et al., 2009). Metodai paremti matematinės morfologijos operacijomis. Sukurtos preliminarios metodikos žingsniai pavaizduoti 21 pav.

Iš pradžių imamas pradinis akies dugno vaizdas I_{init} (21.1 pav.). Vaizdui taikomas CLAHE (angl. *Contrast Limited Adaptive Histogram Equalization*) metodas (21.2 pav.). Taikomi 5×5 medianos (21.3 pav.) ir 7×7 dydžio Gauso filtrai (21.4 pav.) su $\sigma=7$. Apdorotas vaizdas I_{pr} analizuojamas toliau. Analizei pasirenkamas žalias – I_G vaizdo kanalas (21.5 pav.).

Išskiriamos pagrindinės kraujagyslės. Matematinės morfologijos uždarymo operacijos $8 \cdot p_s \times 8 \cdot p_s$ (21.7 pav.) ir $4 \cdot p_s \times 4 \cdot p_s$ (21.9 pav.) atliekamos su I_G vaizdu, čia p_s yra skalės parametras, naudojamas filtrams ir kitoms operacijoms priderinti prie skirtingų rezoliucijų vaizdų. Šis parametras detalizuojamas 4.2.1 skyriuje. Po matematinės morfologijos uždarymo operacijų gautus vaizdus atėmus vieną iš kito, gaunamas vaizdas I_{vs} (21.10 pav.). I_{vs} vaizdui atliekama slenksčio operacija nuo $\max(I_{vs}) \cdot 0,1$ iki 255. Gautam binariniam vaizdui taikomas 11×11 dydžio medianos filtras pašalinti izoliuotoms dalims. Per apdorojimą gaunamas pagrindinių kraujagyslių tinklas I_{vm} (21.11 pav.). Pagrindinių kraujagyslių tinklui

atliekama ploninimo operacija ir šalinami izoliuoti taškai. Gaunamas pagrindinių kraujagyslių suplonintas tinklas I_{vr} (21.12 pav.).




21 pav. Automatinės akių dugno analizės metodikos iliustracija.

Preliminarus optinio nervų disko centro OD_p nustatymas. Naudojant I_{vr} atliekama linijų radimo Hofo transformaciją parenkamos linijos, kurių pokrypis yra didesnis kaip 45° ir kurios surenka daugiau kaip $20 p_s$ balsų. Iš parinktų linijų, kurių poslinkio skirtumas ne mažesnis kaip 1° , sudaromas susikirtimų žemėlapis (21.13 pav.). Šiam žemėlapiui atliekama morfologinė auginimo operacija su $5 \cdot p_s \times 5 \cdot p_s$ (21.14 pav.). Gautas rezultatas sudedamas su vaizdu I_G (21.15 pav.). Gautas vaizdas suliejamas $30 \cdot p_s \times 30 \cdot p_s$ dydžio Gauso filtru (21.16 pav.). Intensyviausias taškas imamas kaip preliminarus optinio nervų disko centras OD_p .

Optinio nervų disko OD_r išskyrimas. Apie preliminarų optinį diską išskiriama $250 p_s$ dydžio kvadratinė sritis (21.17 pav.). Kraujagyslėms pašalinti atliekama $25 \cdot p_s \times 25 \cdot p_s$ dydžio morfologinė uždarymo operacija (21.18 pav.). Gautas vaizdas suliejamas $4 \cdot p_s \times 4 \cdot p_s$ dydžio Gauso filtru (21.19 pav.). Su Sobel filtru gaunamas vaizdo gradientas (21.21 pav.), jam atliekama slenksčio operacija nuo 7 iki 255 (21.22 pav.). Naudojant

apskritimų Hofo transformaciją imamas geriausias apskritimas, esantis arčiausiai preliminarus OD_p optinio disko centro. Šis apskritimas laikomas tikroju optiniu nervų disku OD_r (21. 23 pav.).



22 pav. Kraujagyslių identifikavimas ir išmatavimas. Balta spalva – OD_r . Mėlyna – OD_{init} centras. Mėlyni brūkšneliai – arterijos, raudoni brūkšneliai – venos.

Kraujagyslių matavimai atliekami AVR matavimų srityje – 2,5 spindulio atstumu nuo optinio nervų disko centro. Metodas matuoja kraujagyslių tinklą I_{vm} ir randa susikirtimus. Tada susikirtimo vietoje matuoja mažiausią plotį nuo $4 p_s$ iki $30 p_s$. Imama po dvi didžiausio pločio kraujagysles į viršų ir į apačią nuo OD_r centro. Tamsesnė atkarpa klasifikuojama kaip vena, o šviesesnė – kaip arterija. Vieno vaizdo klasifikavimas pateiktas 22 pav.

Preliminarūs metodikos tyrimai parodė, kad klaidos klasifikavimo ir kitų etapų metu atsiranda dėl netolygaus apšvietimo, persidengiančių kraujagyslių ir įvairių artefaktų. Išskirtas kraujagyslių tinklas daro labai didelę įtaką bendram sprendiniui. Bendras filtrų taikymas pirminiam vaizdų apdorojimui nėra universaliai tinkamas visiems etapams.

4.2. Akies dugno kraujagyslių matavimas

Akies dugnas susideda iš įvairių anatominių struktūrų. Šių struktūrų tyrimas gali būti labai svarbus tokių ligų, kaip arterinė hipertenzija, diabetinė retinopatija, amžinė makulos degeneracija ir glaukoma, diagnozei (Kanski, 2007). Pokyčiai makuloje rodo amžiaus paveiktą makulos degeneraciją (Kanagasingam et al., 2014). Optinis diskas ir ekskavacija yra tiriami

glaukomai nustatyti (Bock et al., 2010), (Buteikienė et al., 2012), (Treigys et al., 2008). Kraujagyslių struktūrų tyrimas yra svarbus ligų, susijusių su kraujo spaudimu, prognozei: choroidinei neovaskuliarizacijai, hipertenzijai, arteriosklerozei ar insultui (Odstrcilik et al., 2013), (Fraz et al., 2012). Kraujagyslių forma ir vingiuotumas, eksudacijos, kraujosruvos, mikroaneurizmai ir dugno tekstūra – ypatybės, leidžiančios diagnozuoti diabetinę retinopatiją.

Svarbiausi yra tokie akies dugno pokyčiai, kurie padeda apsaugoti ir nuo besivystančių ne akių ligų progresavimo. Sprendimai apie besivystančias ligas gali būti priimami remiantis venų ir arterijų santykio matavimais prieš ir po fizinio krūvio (žr. Morgan et al., 2007). Dar daugiau, venų ir arterijų santykis gali būti veikiamas ne vien fizinės, bet ir psichinės tiriamojo būklės. Automatizuoti santykio matavimus gana sudėtinga, nes arterijas ir venas yra labai sunku atskirti (Mirsharifa et al., 2013), (Kondermann et al., 2007), (Li et al., 2014). Santykio matavimus atlikti taip pat sudėtinga ir dėl to, kad santykio pokyčiai atsiranda mikro lygmenyje. Yra nemažai pasiūlytų arterijų ir venų segmentavimo metodų, tačiau labai reikšmingų rezultatų nėra dėl pažangiausių metodų ribotumo ir naudojamos techninės įrangos. Rezultatams turi įtakos prastas segmentavimas, kai kraujagyslėse matomas vidinis šviesos atspindys, taip pat prastas segmentavimas išsišakojimuose, susikirtimuose ir persidengimuose. Kraujagyslės arti viena kitos gali būti atpažintos kaip viena, o plonos kraujagyslės gali būti praleistos. Kai kuriose vietose kraujagyslės gali būti klaidingai suklasifikuotos. Tai ypač būdinga regione šalia optinio disko (*OD*) kraštų arba patologiniuose akies dugno regionuose (Nguyen et al., 2013).

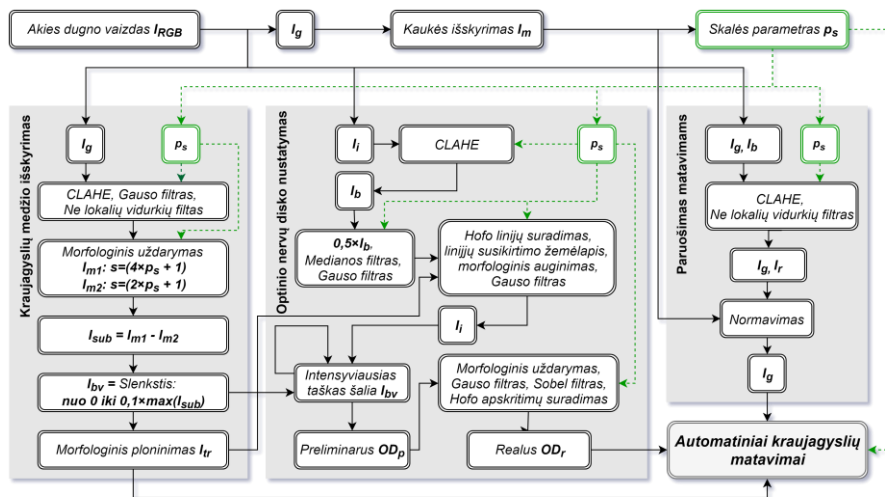
Remiantis literatūros analize, akies dugno kraujagyslių segmentavimo metodai gali būti suskirstyti į šešias kategorijas (Fraz et al., 2012):

- Priderinto filtravimo metodų taikymas.
- Daugiasluoksnės analizės metodų taikymas.
- Atpažinimo teorijos metodų taikymas.
- Kraujagyslių sekimo metodai.
- Modeliu paremtų technikų taikymas.
- Matematinės morfologijos metodai.

Kaip aprašoma literatūroje (žr. Fraz et al., 2012, Li et al., 2014, Niemeijer et al., 2011), daugelis vaizdų analizės metodų taikomi aukštos kokybės vaizdams, gautiems stacionariomis akies dugno kameromis, tačiau šios yra labai brangios ir jas sunku naudoti sudėtingomis sąlygomis, kai reikia

nustatyti objektyvią tiriamojo fizinę ir psichinę būklę. Pirminėse sveikatos įstaigose ankstyvajai diagnozei naudojamos mobiliosios kameros, kurių vaizdų kokybė yra vienoda, lyginant su aukso standartu. Šiame darbe pateikiamas metodas paremtas kraujagyslių sekimu ir matematinės morfologijos metodais. Metodas skirtas išmatuoti kraujagyslių diametrų pokyčius nurodytose vietose akių dugno vaizduose prieš ir po fizinio krūvio. Matavimai atliekami kairės ir dešinės akių dugnų vaizduose. Toliau aptariamas ekspertų ir sistemos matavimų rezultatų lyginimas. Tyrimui naudojami vaizdai gauti Optomed OY skaitmenine mobiliąja akies dugno kamera Smartscope M5 PRO. Remiamasi metodais, pateiktais straipsniuose (Ravishankar et al., 2009), (Pachiyappan et al., 2012). Metodo (Stabingis et al., 2017) naujumas yra tas, kad jis veikia su skirtingų dydžių vaizdais, nes naudojamas skalės parametras p_s . Geresnis požymių gavimas pasiekiamas skirtingais pirminio apdorojimo metodais skirtingiems metodo etapams. Pateikiamas naujas kraujagyslių pločio matavimo metodas, kuris veikia nepriklausydamas nuo gauto kraujagyslių medžio. Siūlomas akies dugno kraujagyslių pločio matavimo metodas susideda iš šių žingsnių (23 pav.):

- Akies dugno dalies kaukės išskyrimas, kuriuo atskiriama akies dugno dalis nuo viso paveiksliuko;
- Skalės parametro p_s įvertinimas;
- Skirtingų pirminio apdorojimo metodų naudojimas skirtingiems etapams;
- Kraujagyslių medžio išskyrimas;
- Optinio nervų disko (*OD*) nustatymas;
- Automatizuotas kraujagyslių pločio matavimas.



23 pav. Visa akies dugno kraujagyslių pločio matavimo metodo schema.

4.2.1. Skalės parametro apskaičiavimas

Pateikiamas akies dugno analizės metodas turi skalės parametą, skirtingus pirminio apdorojimo metodus ir kitas adaptavimo priemones originalaus dydžio vaizdams. Siūlomas toks apibendrintas parametro apskaičiavimas:

$$p_s = \frac{\beta_1}{1 + \beta_2 \exp\left(-\frac{W_M}{\beta_3}\right)} + \frac{W_M}{\beta_4}, \quad (18)$$

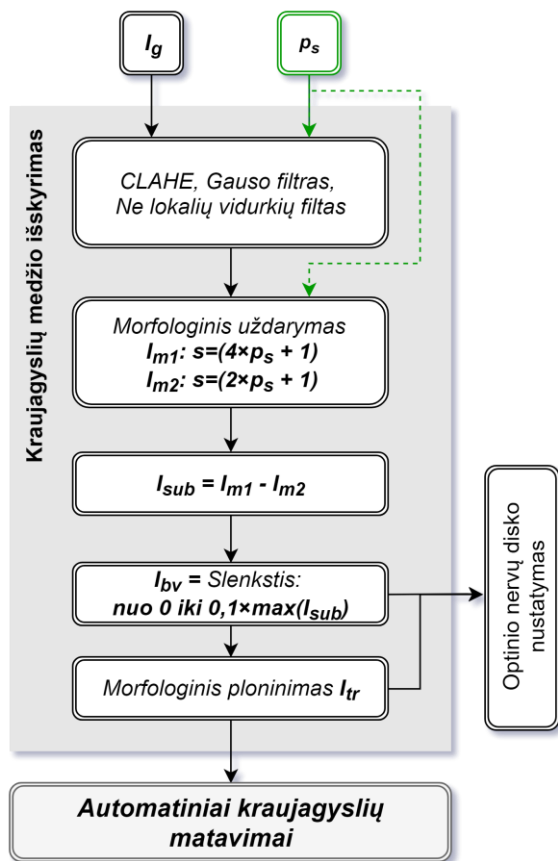
čia $\beta_1, \beta_2, \beta_3$ yra logistinio augimo modelio dalies parametrai, β_4 yra tiesinės modelio dalies parametras. Parinktos šios parametų reikšmės: $\beta_1 = 4, \beta_2 = 20, \beta_3 = 500$ ir $\beta_4 = 3000$. W_M yra akies dugno dalies kaukės I_M plotis taškais. I_M kaukė iš vaizdo išskiriama slenksčio operatoriumi ir atliekant matematinės morfologijos uždarymo operaciją. Akies dugno dalis vaizde yra apskritimo formos, o už jos yra juodos spalvos sritis. Slenksčio operatoriumi atskiriama tik akies dugno dalis nuo fono. Kadangi akies dugno dalyje gali būti smulkių juodos spalvos elementų, jiems prijungti prie akies dugno dalies atliekama matematinės morfologijos uždarymo operacija. Taip gaunama vaizde esančios akies dugno dalies sritis – kaukė. Skalės parametro p_s apskaičiavimo formulė (18) pritaiko vaizdus prie FOV (angl. *Field Of View*) skirtingų reikšmių. Naujesnės akies dugno kameros ne tik daro didesnės rezoliucijos vaizdus, bet ir aprėpia didesnę akies dugno plotą. Šiuolaikinėms akies dugno kameroms yra būdinga $45^\circ, 50^\circ$ FOV reikšmė. Senesnėms akies dugno kameroms,

darydavusioms mažesnės raiškos vaizdus, būdavo svarbu kuo daugiau užfiksuoti tam tikras akies dugno sritis. Todėl būdavo fotografuojama su mažesnėmis FOV reikšmėmis. Universalus metodas, pritaikytas naudoti su skirtingais vaizdais be papildomo priderinimo, turi atsižvelgti į galimas mažesnes FOV reikšmes mažesnės rezoliucijos vaizduose. Pagal (18) formulę apskaičiuotas p_s parametras toliau yra naudojamas beveik visuose siūlomo metodo etapuose.

4.2.2. Kraujagyslių išskyrimas ir optinio nervų disko nustatymas

Optinis nervų diskas (*OD*) yra atskaitos taškas analizuojant akies dugno vaizdus. Todėl ypač svarbu vaizduose tiksliai nustatyti optinį nervų diską. Metodas, pasiūlytas (Ravishankar et al., 2009), (Pachiyappan et al., 2012) straipsniuose, naudoja išskirtą kraujagyslių tinklą padidinti *OD* nustatymo tikslumui. Išplėtotas kraujagyslių išskyrimo ir *OD* nustatymo metodas plačiau aprašytas straipsnyje (Stabingis et al., 2016).

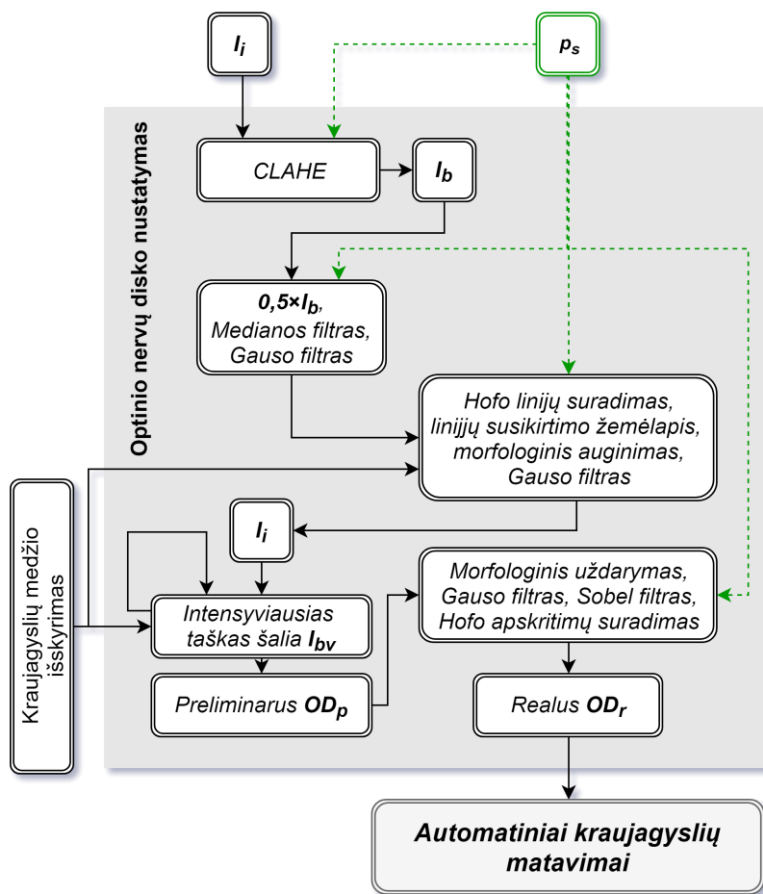
Kraujagyslių išskyrimo metodas (24 pav.) yra paremtas matematinės morfologijos uždarymo operacija. Morfologinės uždarymo operacijos (žr. 2.2.1 skyrių), kurių struktūrinių elementų dydžiai $(4 \cdot p_s + 1 \times 4 \cdot p_s + 1)$ ir $(2 \cdot p_s + 1 \times 2 \cdot p_s + 1)$ yra pritaikomi žaliajam vaizdo kanalui I_G , apdorotam pagal schemą, pateiktos 23 pav. ir 24 pav. Kuo didesnis uždarymo operacijos struktūrinio elemento dydis, tuo didesnės kraujagyslės gali būti išskiriamos. Po uždarymo operacijų atliekama gautų vaizdų atimties operacija. Vaizdų skirtumui taikoma slenksčio operacija ir gaunamas galutinis binarinis vaizdas, kuriame yra tik kraujagyslių tinklas. Paskui gautas kraujagyslių binarinis vaizdas yra ploninamas atliekant morfologinę ploninimo operaciją, taip suformuojamas kraujagyslių medis I_{tr} . Trumpi kraujagyslių medžio segmentai yra šalinami siekiant sumažinti triukšmą. Kraujagyslių tinklo medis yra naudojamas tolesniuose metodo etapuose.



24 pav. Kraujagyslių tinklo išskyrimo schema.

Optinio nervų disko (OD) nustatymo metodas susideda iš dviejų etapų (25 pav.). Pirmajame etape surandamas preliminarus OD_p . Pirmiausia, remiantis Hofo linijų transformacija (Gonzalez et al., 2018), pagal I_{tr} sudaromas linijų susikirtimo žemėlapis. Gautam žemėlapiui atliekama morfologinė auginimo operacija ir gautas rezultatas sudedamas su apdorotu intensyvumo kanalu. Taikomas didelio šablono Gauso filtras ir intensyviausias taškas parenkamas kaip OD_p regionas. Tačiau tam tikrais atvejais OD_p yra nustatomas neteisingoje vietoje dažniausiai dėl tam tikrų vaizdo gavimo metu atsirandančių klaidų. Norint to išvengti, OD_p nustatymo metodas yra papildytas sąlyga, kad nustatyto OD_p aplinkoje būtų išskirtų kraujagyslių. Jei ši sąlyga netenkinama, nustatytas OD_p yra atmetamas ir ieškomas kitas intensyviausias taškas. Nustačius teisingą OD_p regioną, atitinkamai sričiai dedamas Sobel gradiento nustatymo filtras (Gonzalez et al., 2018) ir taikoma Hofo apskritimų transformacija. Arčiausiai OD_p centro esantis apskritimas

parenkamas kaip realus optinis nervų diskas OD_r . Remiantis nustatytu OD_r , visi matavimai atliekami spinduliu nuo $2 \cdot OD_r$ iki $3 \cdot OD_r$ nuo OD_r centro.

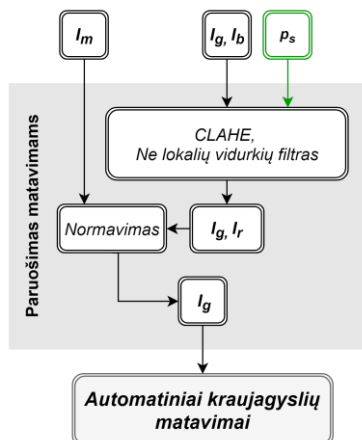


25 pav. Optinio disko nustatymo etapo schema.


4.2.3. Kraujagyslių pločio matavimų metodas

Pagrindinis metodo tikslas – padaryti kraujagyslių matavimus kiek įmanoma nepriklausomus nuo išskirto kraujagyslių tinklo I_{tr} . Matavimai atliekami pagal pradinį vaizdą, o kraujagyslių vaizdas I_{tr} , gautas po ploninimo operacijos, naudojamas tik kaip priemonė parinkti pradinio matavimo kampą. Tai leidžia atlikti matavimus ir vietose, kuriose kraujagyslės dar nebuvo išskirtos, taip pat išvengti kraujagyslių išskyrimo klaidų ir sumažinti pastarųjų įtaką galutiniams tikslumui. Matavimų schema yra tokia:

- Pradinis vaizdo apdorojimas, skirtas matavimams, atliekamas pagal 23 pav. ir 26 pav.;
- Pasirenkamas I_G kanalas;
- Matavimai atliekami taške $s_c = (x_c, y_c)$;
- Profilio informacija yra gaunama remiantis 27 pav.;
- Apskaičiuojamas kraujagyslės plotis (pagal 28 pav.);
- Matavimai atliekami profilį imant skirtingais kampais 1° intervalais.
- Kampas α , kur apskaičiuotas plotis yra mažiausias, laikomas geriausiu.
- Pagal nustatytą kampą įvertinti didesnei kraujagyslės daliai daliai išilgai kraujagyslės atliekama papildomų matavimų. Kiekvienam vertinimui naudojama 20 kraujagyslės segmentų.
- Pirmasis kraujagyslės pločio vertinimas atliekamas tikrinant kampus intervale $[0^\circ; 180^\circ]$, o kiti matavimai – intervale $[\alpha-45^\circ; \alpha+45^\circ]$ pagal ankstesniame žingsnyje nustatytą kampą α .
- Jei šalia vertinamos vietos yra išskirtas kraujagyslių medis I_{tr} , jis naudojamas kampui α nustatyti, o matavimai vykdomi intervale $[\alpha-12^\circ; \alpha+12^\circ]$.
- Apskaičiuojamas kraujagyslės dalies segmentų pločių vidurkis \overline{wd} ir standartinis nuokrypis σ_p . Kraujagyslės dalies pločiui apskaičiuoti parenkami tik tie segmentai, kurių plotis patenka į intervalą $\overline{wd} \pm \sigma_p$.
- Vidutinis kraujagyslės plotis pagal parinkus segmentus naudojamas kaip kraujagyslės plotis.



26 pav. Vaizdų paruošimas automatiniais kraujagyslių pločio matavimams.



27 pav. Kraujagyslės profilio gavimo schema.

Kraujagyslės profilis – tai tam tikras jos vaizdo skersinis pjūvis, tam tikru kampu α apimantis kraujagyslę ir jos aplinką. 27 pav. pateiktas profilio informacijos gavimo algoritmas. Čia s_c yra taškas, kuriame atliekami matavimai. Ties tašku s_c imama $30 \cdot p_s$ ilgio atkarpa. α nurodo atkarpos pasvyrimo kampą. Atkarpa skaidoma į $n_{stp} = 100$ žingsnių. Kiekviename žingsnyje j ties tašku s_j apskaičiuojama intensyvumo reikšmė v_j pagal arčiausiai esančių taškų aibę J , susidedančią iš vaizdo taškų, nutolusių nuo taško s_j atstumu $d(s_i, s_j) < 3$, kur $s_i \in J$.


$$v_j = \frac{\sum_{s_i \in J} z_i \cdot h_{ij}}{\sum_{s_i \in J} h_{ij}}, j = 1 \dots n_{stp}, \quad (19)$$

$$h_{ij} = \begin{cases} 1 - \frac{d(s_i, s_j)}{3}, & \text{kai } d < 3, \\ 0, & \text{kai } d \geq 3 \end{cases}, \quad (20)$$

čia $d(s_i, s_j)$ yra Euklido atstumas tarp taškų s_i ir s_j , o z_i yra s_i taško intensyvumo reikšmė.


Gauti profilio duomenys naudojami tolesnei analizei įvertinti kraujagyslės pločiui. Šis procesas pavaizduotas 28 pav. Profilio centre, $j \in \left[\frac{n_{stp}}{2} - 15; \frac{n_{stp}}{2} + 15 \right]$, randamas minimumo taškas. Nustatomi kairysis ir dešinysis minimumo taškai (28.a pav.). Nuo šių taškų profilis analizuojamas dviem skirtingomis kryptimis randant lokalaus maksimumo tašką (28.b pav.). Randamas greičiausio nusileidimo taškas (28.c pav.) tarp a ir b taškų – $s_c = \operatorname{argmax}_{j=b \dots a} (v_j - v_{j-1})$. Randami du ribiniai taškai (28.d pav.), kuriuose nusileidimo reikšmė yra intervale $[max - \sigma_w; max]$. Čia σ_w yra nusileidimų

reikšmių tarp taškų a ir b standartinis nuokrypis. Centrinis taškas (28.e pav.) tarp d taškų yra imamas kaip geriausias kraujagyslės pločio matavimams.



28 pav. Profilio analizė: kraujagyslės pločio įvertinimas.

Profilio analizės schema pateikta 28 pav. Čia pilka spalva pavaizduota paimto profilio informacija. Raudona spalva – profilio informacija su Gauso filtru. Mėlyna spalva – skirtumai tarp gretimų taškų. a) minimumų taškai; b) lokalūs maksimumų taškai; c) didžiausio nusileidimo taškai; d) didelio nusileidimo kraštiniai taškai panašūs į c; e) vidurio taškai tarp e taškų, pagal kuriuos apskaičiuojamas kraujagyslės plotis.

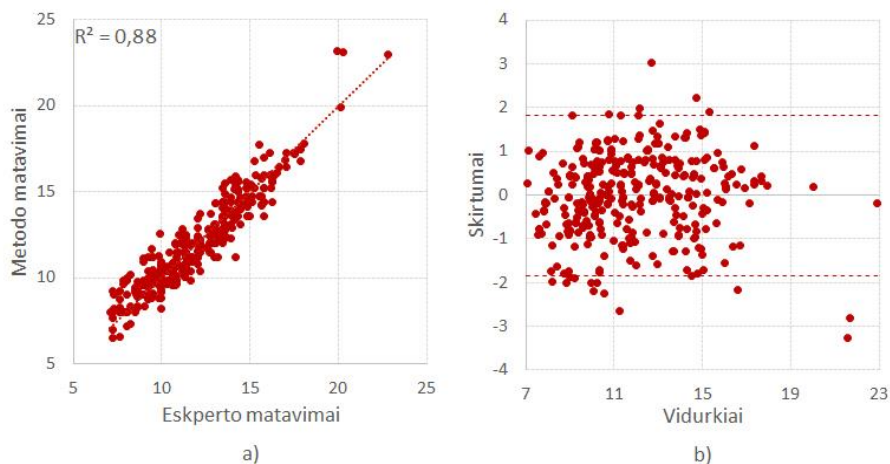


29 pav. Matavimo metodo etapų iliustracija.

Kaip pateikta 29 pav., matavimų metodas tam tikrame taške keisdamas kampą α renka atitinkamo profilio informaciją, paskui atlikęs jos analizę, įvertina kraujagyslės plotį. Profilis su mažiausiu kraujagyslės pločiu laikomas statmenu matuojamai kraujagyslei. Algoritmas tęsiamas matuojant profilius išilgai kraujagyslės, kituose matavimuose analizuojamas mažesnis profilių kiekis skirtingais kampais.

4.2.4. Kraujagyslių pločio matavimų rezultatai

Pasiūlytam metodui įvertinui naudoti 86 vaizdai, kiekviename iš jų matuota po keturias kraujagysles: abi pagrindinės viršutinės ir abi pagrindinės apatinės (atskaitos tašku imamas OD_r centro taškas). Iš viso atlikti 344 matavimai. Visi vaizdai gauti Optomed OY skaitmenine mobiliąja akies dugno kamera Smartscope M5 PRO. Naudotų vaizdų bazė toliau vadinama OPTO-AVR. Ekspertų ir pateikto metodo matavimai buvo atliekami tuose pačiuose taškuose. 30 pav. pateikti ekspertų ir pateikto metodo atlikti matavimai. Patikrinus statistinę hipotezę galima teigti, kad abiem būdais atlikti matavimų rezultatai yra vienodi. Pagrindinės charakteristikos pateiktos lentelėje 4.



30 pav. Kraujagyslių pločių matavimų rezultatai. Matavimai atlikti ekspertų ir pateikto metodo: a) sklaidos diagrama, b) Bland-Altman diagrama.

Lentelė 4. Kraujagyslių matavimo rezultatų charakteristikos.


Matavimai atlikti	Ekspertų	Pateikto metodo
Vidurkis	11,858	11,865
Dispersija	7,482	7,241

Kraujagyslių matavimų lyginimo t-testo su $\alpha = 0,95$ charakteristikos yra lygios $t_{stat} = -0,036$, kritinė reikšmė šiuo atveju $t_{krit} = 1,963$.

H_0 neatmetame – matavimai vienodi.

Toliau tiriamas arterijų ir venų santykis. Santykis turi rodyti atsirandančios ligos pradžią. Santykis apskaičiuotas pagal ekspertų ir pagal pateikto metodo matavimus. Rezultatai pateikti 31 pav. ir Lentelė 5. Pagal statistinę hipotezę

su 95 % pasiklovimo galima teigti, kad abiem būdais atlikti matavimai yra vienodi. Pagal 31 pav. galima matyti, kad matavimų paklaida didėja, kai didėja apskaičiuoto santykio reikšmės. Normalus santykis turėtų būti apie 0,7, o didesni santykiai įprastai nustatomi probleminėms vietoms arba prastesnės kokybės vaizdams.



31 pav. Arterijų ir venų santykio rezultatai. Matavimai atlikti ekspertų ir pateikto metodo: a) sklaidos diagrama, b) Bland-Altman diagrama.

Lentelė 5. Arterijų ir venų pločio santykis, apskaičiuotas 172 kraujagyslių poroms.

Matavimai atlikti	Ekspertų	Pateikto metodo
Vidurkis	0,743	0,734
Dispersija	0,019	0,021

Arterijų ir venų pločių santykio matavimų lyginimo t-testo su $\alpha = 0,95$ charakteristikos yra lygios $t_{\text{stat}} = 0,595$, kritinė reikšmė šiuo atveju $t_{\text{krit}} = 1,967$. H_0 neatmetame – matavimai vienodi.

4.3. Adaptyvus AVR matavimams naudojamų kraujagyslių klasifikavimas

Šiame skyriuje pasiūlytas adaptyvus klasifikavimo metodas, skirtas klasifikuoti kraujagysles, kurios naudojamos AVR apskaičiuoti. Šis metodas publikuotas straipsnyje (Stabingis et al., 2018). Metodas skirtas visiškai automatiniam AVR apskaičiavimui. Taip pat šis metodas eliminuoja 4.1

skyriuje iškeltas problemas ir atsižvelgia į 2.4 skyriuje pateiktas erdvinės informacijos taikymo galimybes.

Svarbus pateikto metodo adaptyvumo rodiklis yra metodo galimybė automatiškai veikti su skirtingo dydžio vaizdais neprarandant vaizdų informacijos ir automatiškai veikti su vaizdais iš nežinomos vaizdų bazės be išankstinio pasirengimo. Taip pat dėmesys skiriamas netolygaus apšvietimo ir triukšmo vaizduose problemoms spręsti.

Viena iš kuriant šį metodą išspręstų problemų yra matavimams tinkamos vietos parinkimas. Kaip minėta anksčiau, ekspertai matavimų vietą parenka iš savo patirties ir matavimus atlieka patogiausioje vietoje. Automatinė sistema matavimų vietas parenka pagal griežtas metode aprašytas taisykles, ir tam tikrais atvejais pasirinkta vieta nėra pati patogiausia matavimams atlikti. Šiame metode AVR matavimų vietos parinkimas susideda iš kelių etapų, iš kurių svarbiausias yra OD nustatymas. OD nustatymas yra būtinas, kad matavimai būtų atliekami tinkamoje vietoje OD aplinkoje. Pagrindinės priežastys, lemiančios netikslų OD nustatymą, yra netolygus vaizdo apšvietimas, ligos paveikti akies dugno pokyčiai, kraujagyslių sukeliamas vaizdo triukšmas OD viduje ir kt. AVR vertinime OD nustatymo etape naudojamas dviejų lygių OD nustatymo metodas, aprašytas 4.1 skyriuje. Šis metodas patikslinamas visiškai automatiniam naudojimui, įvedant papildomas OD aptikimo taisykles, aprašytas 4.3.2 skyriuje.

AVR apskaičiuoti būtina išmatuoti pagrindinių kraujagyslių pločius. Matavimams yra naudojamas kraujagyslių pločio matavimų metodas, pateiktas (Stabingis et al., 2017). Šis metodas plačiai aprašytas 4.2 skyriuje. Profilio informacija dažnai gaunama Bresenghamo algoritmu, kuris informaciją gauna greitai, tačiau gautos informacijos taškai tam tikrose situacijose gali būti pasiskirstę netolygiai. Pateikiamas profilio analizės metodas surenka informaciją, taikant atstumo funkciją, ir leidžia automatiškai taikyti tą patį profilio analizės algoritmą adaptyviai su skirtingos rezoliucijos vaizdais. Taip pat šis matavimų metodas gali pats atpažinti kraujagyslės buvimą vaizduose be išankstinio žinojimo, ar toje vietoje yra kraujagyslė. Gautas kraujagyslių medis naudojamas tik pradinei kryptiškai parinkti, ir tik tais atvejais, kai turima šio medžio informacija. Kraujagyslės yra randamos ir išmatuojamos AVR matavimų zonoje, o tada atliekamas kraujagyslių klasifikavimas.

Pateikiamas metodas yra skirtas automatiniam kraujagyslių klasifikavimui ir siekiama šį metodą taikyti skirtingo tipo vaizdams, nepaisant įrangos, kuria jie gauti. Tam būtina taikyti klasifikavimo be mokymo metodus. Klasifikavimo su mokymu metodai yra tikslesni, tačiau jie turi būti

priderinami prie skirtingo tipo vaizdų. Kartais ir ta pačia įranga gautiems vaizdams negali būti taikomas jau apmokytas metodas dėl vaizdo triukšmingumo, apšvietimo ar kitų su vaizdų kokybe susijusių problemų. Dar vienas iš pateikiamo metodo privalumų yra galimybė kuo labiau sumažinti galimo netolygaus apšvietimo įtaką. Pateikiamame metode taikomas k -vidurkių klasterizavimo algoritmas ir erdvine informacija paremtas požymių perskaičiavimas, sumažinantis netolygaus apšvietimo įtaką.

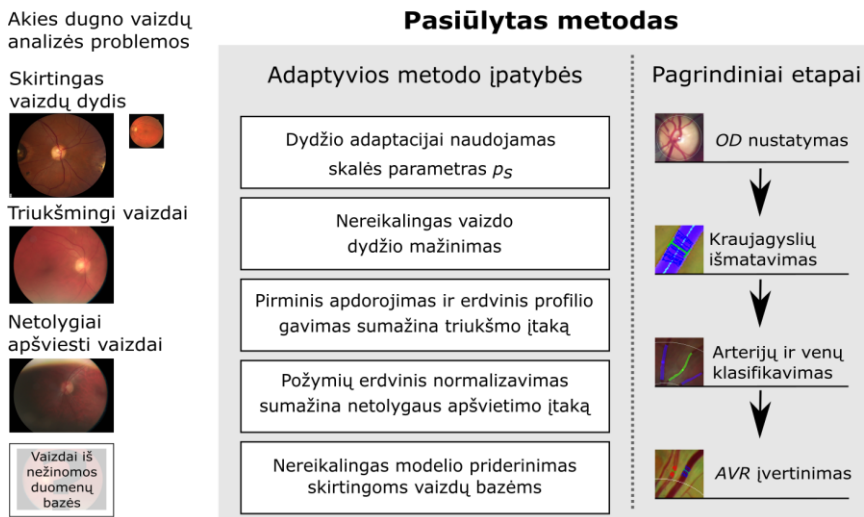
Akies dugno kraujagyslėms klasifikuoti, kaip ir daugeliui kitoms vaizdų analizės problemoms spręsti, naudojama daug skirtingų požymių. Pateikiamame metode klasifikavimui siūlomi nauji požymiai, paremti per matavimus surinkta profilio informacija ir specifiniai akies dugno vaizduose esančioms kraujagyslėms. Šie požymiai atitinka kraujagyslės viduje esančią informaciją, kuri adaptyviai suvidurkinta išilgai analizuojamos kraujagyslės dalies.

Klasifikavimo tikslumas yra lyginamas su kitais klasifikavimo metodais, naudojamais akies dugno kraujagyslėms klasifikuoti *AVR* matavimų zonoje. Lyginimas atliekamas naudojant viešas akies dugno vaizdų duomenų bazes *IVSIPIRE-AVR* (Niemeijer et al., 2011) ir *DRIVE* (Staal et al., 2004). *DRIVE* vaizdų bazė yra labai dažnai naudojama lyginimui sprendžiant ir kitas akies dugno analizės problemas. Tačiau ši bazė jau sena ir vaizdai, nors ir yra geros kokybės triukšmo atžvilgiu, yra mažos rezoliucijos. Modernios akies dugno vaizdų kameros gauna daug didesnės raiškos vaizdus, todėl *DRIVE* duomenų bazės vaizdai gali būti laikomi nebeaktualiais. Ši bazė yra naudojama tik demonstraciniais tikslais, siekiant parodyti metodo automatinį prisiderinimą prie bet kokios rezoliucijos vaizdų ir klasifikavimo tikslumo išlaikymą. Pateikiamas klasifikavimo metodas yra lyginamas su kitais metodais, pateiktais straipsniuose (Renukalatha et al., 2018), (Muramatsu et al., 2011), (Mirsharifa et al., 2013), (Niemeijer et al., 2011). Yra ir daugiau akies dugno klasifikavimo metodų, tačiau lyginimui atrinkti tik tie metodai, kurie skirti *AVR* įvertinti naudojant tik *AVR* matavimų zonos kraujagysles. Pateiktas kraujagyslių dalių, o ne atskirų visų *AVR* matavimų zonos taškų ar visų kraujagyslių centro linijos taškų klasifikavimas. Tokiais atvejais deklaruojamas klasifikavimo tikslumas būna žymiai didesnis. Metodas taip pat testuojamas ir su *OPTO-AVR* vaizdų baze, naudota kraujagyslių pločio matavimo metodo tyrimui.

4.3.1. *AVR* įvertinimo metodas

Straipsnyje (Stabingis et al., 2018) publikuotas metodas skirtas automatiškai įvertinti *AVR* parametą iš akies dugno vaizdų. Pagrindinė šio metodo ypatybė

yra adaptyvumas. Šis metodas automatiškai prisitaiko prie skirtingos raiškos vaizdų, nemažindamas jų ir taip neprarasdamas informacijos. Jokie metodo parametrai neturi būti derinami prie skirtingo tipo vaizdų. Naudojamas vienas bendras metodas, skirtingoms vaizdų bazėms nekuriami skirtingi modeliai su skirtingais parametrais. Kuriant metodą atsižvelgta į galimą vaizdų triukšmą ir į galimą netolygų vaizdų apšvietimą. Metodo pagrindinių ypatybių schema pateikta 32 pav. Šiuo metodu visi analizės žingsniai atliekami automatiškai.

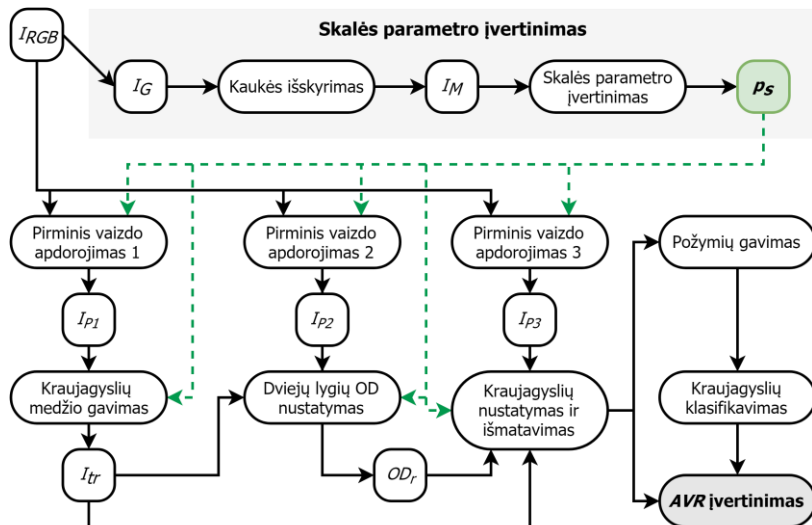


32 pav. Pagrindinės adaptyvumo ypatybės, lyginant su ne tokiais adaptyviais metodais.

Pagrindiniai metodo veikimo žingsniai pateikti 33 pav. Akies dugno vaizdų žalios spalvos kanalas I_G naudojamas akies dugno dalies kaukei I_M išskirti. Kaukė išskiriama įprastais vaizdų analizės būdais. Taikomas slenksčio operatorius, tada imama intesyvesnė dalis, atliekamos matematinės morfologijos uždarymo ir užpildymo operacijos. Suformuojama apvali kaukė, atitinkanti akies dugno dalį. I_M toliau naudojama skalės parametrai p_s apskaičiuoti pagal formulę (18). Gauta akies dugno dalies kaukė I_M toliau naudojama daugeliui žingsnių: vaizdams normuoti, filtruoti ir kt.

Vaizdų pirminis apdorojimas padeda iš dalies suvienodinti skirtingus vaizdus ir išryškinti tam tikrus vaizdų požymius. Daugelyje vaizdų analizės metodų vaizdų pirminis apdorojimas laikomas ypač svarbiu. Pateikiamas metodas taiko keletą skirtingų pirminio apdorojimo algoritmų skirtinguose etapuose. Kiekviename etape taikomas specialus algoritmas. Taip

išsprendžiama problema, kai tam tikras pirminis apdorojimas padeda geriau identifikuoti OD , bet tuo pačiu pablogina kraujagyslių klasifikavimą.



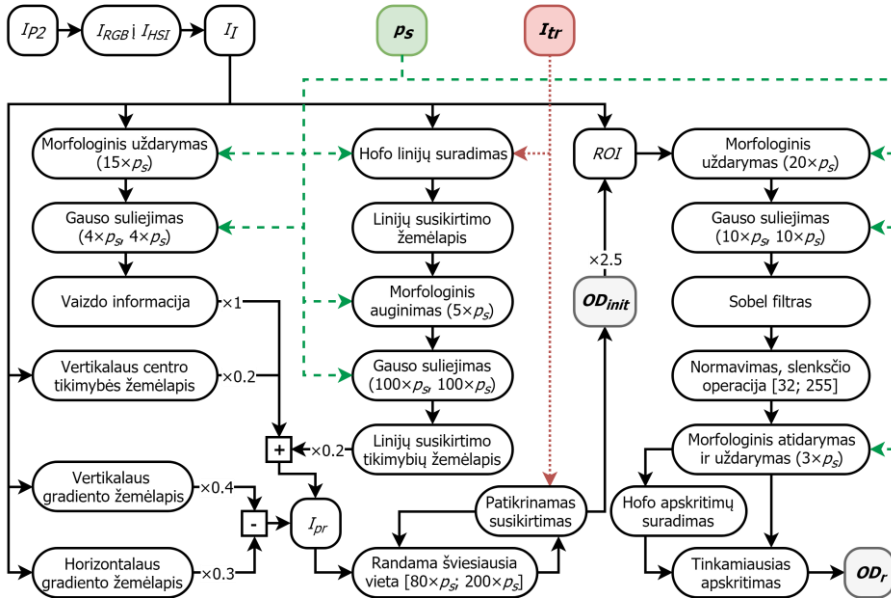
33 pav. Pagrindiniai AVR įvertinimo metodo žingsniai.

Kraujagyslių tinklo I_{tr} išskyrimo etapas nėra svarbus pateikiamam metodui, kadangi kituose etapuose I_{tr} informacija naudojama tik kaip pagalbiniė. Daugelyje kitų akies dugno analizės metodų I_{tr} išskyrimo etapas yra beveik pats svarbiausias, nes išskirtas kraujagyslių medis toliau naudojamas kaip atskaitos elementas beveik visuose etapuose. Etapų priklausomybė nuo išskirto I_{tr} gali vesti prie klaidų, ypač sergančių pacientų atveju, nes kai kurie elementai gali įgyti į kraujagyslę panašią formą ar kraujagyslių ir jas supančios aplinkos kontrastas gali būti per mažas ir išskyrimo metu susiformuoti kraujagyslių trūkiai. Yra keletas įprastai taikomų akies dugno kraujagyslių išskyrimo metodų (žr. Pachiyappan, et al., 2012, Balkys, et al., 2012). Išskirti naudojami slenksčio operatorius, matematinė morfologija, Gaboro filtravimas, vilnelės ir kt. Yra sukurta ir tikslesnių metodų, tačiau jie susideda iš daugelio etapų ir reikalauja daugiau skaičiavimo resursų. Pateiktas metodas remiasi matematinė morfologija (Stabingis et al., 2017). Tačiau, kaip jau minėta anksčiau, visi metodo žingsniai gali veikti ir be išskirto I_{tr} kraujagyslių medžio.

4.3.2. Optinio nervų disko išskyrimas

OD išskyrimo metodas susideda iš dviejų etapų. Pirmame etape randamas preliminarus OD_{init} , antrame etape surandamas ir įvertinamas realus OD_r .

apskritimas. Per antrą etapą priderinamas apskritimas prie apskritimo formos šviesaus objekto, nustatyto per pirmą etapą. Visa OD nustatymo schema pateikta 34 pav.



34 pav. Dviejų etapų OD nustatymo schema, naudojama AVR matavimuose.

Pirmame OD_{init} nustatymo etape randama preliminari OD lokacija. Suformuojamas OD buvimo vietos vaizde tikimybės žemėlapis I_{pr} . Ši tikimybė priklauso nuo šių dydžių:

- Vaizdo I_I (koeficientas 1)
- Kraujagyslių susikirtimo žemėlapio I_{LInt} (koeficientas 0,2)
- Vertikalios centro tikimybės žemėlapio I_{VCent} (koeficientas 0,2)
- Vertikalios gradiento žemėlapio I_{VGr} (koeficientas -0,4)
- Horizontalios gradiento žemėlapio I_{HGr} (koeficientas -0,3)

I_{pr} tikimybės apskaičiuojamos pagal (21) formulę:

$$I_{pr} = 1 \cdot I_I + 0,2 \cdot I_{LInt} + 0,2 \cdot I_{VCent} - 0,4 \cdot I_{VGr} - 0,3 \cdot I_{HGr}. \quad (21)$$

Suformuotas tikimybės žemėlapis I_{pr} naudojamas ieškant intensyviausio apskritimo formos objekto, kurio spindulys yra nuo $80 \cdot p_s$ iki $200 \cdot p_s$ ir kuris susikerta su I_{tr} .

Paprastai akies dugno vaizdai, naudojami AVR matavimams, yra fotografuojami taip, kad OD būna arti vertikalaus centro. Norint įterpti šią erdvinę informaciją į OD nustatymą, suformuojamas vertikalaus centro tikimybės žemėlapis pagal formulę (22).

$$I_{VCent}(i, j) = \frac{\beta_v \cdot h}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{\left(i-\frac{h}{2}\right)^2}{2\sigma^2}\right), \quad (22)$$

kur h yra I_I vaizdo aukštis, $\sigma^2 = \left(\frac{h/2}{3}\right)^2$, β_v yra intensyvumo valdymo parametras (čia $\beta_v=100$), i yra vaizdo eilutės numeris, o j yra vaizdo stulpelio numeris.

Norint sumažinti netolygaus apšvietimo įtaką, apskaičiuojami vertikalaus ir horizontalaus gradiento žemėlapiai. Vertikalaus gradiento žemėlapis I_{VGr} apskaičiuojamas išvedant kiekvienos eilutės informacijos vidurkį, o horizontalaus gradiento žemėlapis I_{HGr} – išvedant vaizdo stulpelių informacijos vidurkį.

Toliau išskiriama ROI (angl. *Region of Interest*) pagal OD_{init} nustatytą apskritimą, padaugintą iš 2,5. Išskirta sritis toliau naudojama OD_r nustatyti taikant keletą filtrų ir Hofo apskritimų radimo algoritmą (žiūrėti 8 pav.).

4.3.3. Kraujagyslių matavimų pritaikymas

Nustačius realų optinį diską, jo spindulį r_{OD} ir centro koordinatas $(x_{OD}; y_{OD})$, ši informacija naudojama kraujagyslių matavimo vietoms nustatyti. Matavimai atliekami išilgai apskritimo, kurio spindulys yra $2 \cdot r_{OD}$, o centras $(x_{OD}; y_{OD})$. Matavimai atliekami penkių vaizdo taškų intervalais, kurie apskaičiuojami pagal formulę (23).


$$\begin{cases} x_i = x_{OD} + (2 \cdot r_{OD} \cdot \cos(\alpha_i)) \\ y_i = y_{OD} + (2 \cdot r_{OD} \cdot \sin(\alpha_i)) \end{cases}, \quad (23)$$

kur $\alpha_i = \alpha_{i-1} + \frac{5}{2 \cdot r_{OD}}$, $\alpha_1 = 0$ ir $\alpha_i \in [0; 2\pi)$.

Matavimai atliekami 4.2.3 skyriuje pateiktu metodu. Metodas automatiškai nustato vietas, kuriose gali būti kraujagyslės. Nustatyta kraujagyslė išmatuojama ir pagal algoritmą matavimai atliekami toliau išilgai kraujagyslės kitų tos pačios kraujagyslės profilių plokščių. Kraujagyslių duomenys surenkami kiekvienai kraujagyslei AVR matavimų srityje $[1,5 \cdot r_{OD}; 3 \cdot r_{OD}]$

(žiūrėti 36 pav.). Tolesniems skaičiavimams naudojamas vidutinis kraujagyslės plotis. Vietose, kur kraujagyslė jau išmatuota, pakartotinai kraujagyslės nebematuojamos.

Kraujagyslių matavimai atliekami analizuojant kraujagyslių profilio informaciją. Profilio informacijos gavimas iš vaizdo detalai aprašytas 4.2.3 skyriuje. Profilio analizės taškai pateikti 35 pav. Netoli centro randamas minimumo taškas. Tada šalia randamas kitas artimas minimumui taškas, siekiant eliminuoti centrinio atspindžio informaciją. Du taškai a_l ir a_r yra naudojami kaip atskaitos taškai kairės ir dešinės profilio pusių analizei. Randami lokalūs maksimumo taškai b_l ir b_r . Tada randami greičiausio nusileidimo takai c_l ir c_r . Randami ribiniai taškai d_{lt} , d_{rt} , d_{lb} , d_{rb} į kairę ir į dešinę, kurie yra panašūs į c_l ir c_r taškus. Randami vidurio taškai e_l (tarp d_{lt} ir d_{lb}) ir e_r (tarp d_{rt} ir d_{rb}), kurie toliau naudojami kraujagyslės pločiui apskaičiuoti.



35 pav. Kraujagyslės profilio analizės schema.

Ši profilio analizė atliekama kraujagyslės vaizdo profiliams, gautiems ties centro tašku $(x_i; y_i)$ skirtingais kampais, o kampas, ties kuriuo plotis įgyja mažiausią reikšmę, laikomas kraujagyslei statmenu. Pirmajam kraujagyslės taško matavimui analizuojami kampai nuo 0° iki 180° , o nustatytas kampas naudojamas tolesnių kraujagyslių dalių matavimams ir toliau analizuojamų kampų kiekis mažinamas. Taip išmatuojamos visų kraujagyslių dalys AVR matavimų srityje $[1,5 \cdot r_{OD}; 3 \cdot r_{OD}]$.

4.3.4. Požymių išskyrimas ir klasifikavimas

Pateikiamame klasifikavimo metode naudojami nauji požymiai. Išanalizavus daug skirtingų kraujagyslių iš skirtingo tipo vaizdų, nuspręsta klasifikavimui

naudoti informaciją iš kraujagyslės vidinės dalies. Dažniausiai venos yra tamsesnės už arterijas, o arterijoms dar yra būdinga šviesesnė centrinio atspindžio linija. Tiek venų, tiek ir arterijų išorinė kraujagyslių dalis neretai yra labai panaši. Klasifikavimui pasirinkti trys požymiai (žr. 35 pav.):

- vidurkis tarp a_l ir a_r taškų;
- vidurkis tarp d_{lb} ir d_{rb} taškų;
- vidurkis tarp $[d_{lb}, a_l]$, ir $[a_r, d_{rb}]$ taškų.

Požymiai apskaičiuojami iš žalios spalvos I_G ir raudonos spalvos I_R vaizdo kanalų atskirai. Šie du kanalai naudojami dėl savo geriausio atskiriamumo ypatybių. Vidutinė reikšmė apskaičiuojama išilgai visos kraujagyslės dalies. Taigi kiekvienai kraujagyslei išskiriami šeši skirtingi požymiai, toliau naudojami klasifikavimui.

Kaip jau minėta, netolygus apšvietimas yra viena iš pagrindinių problemų, lemiančių neteisingą kraujagyslių klasifikavimą. Norint sumažinti šią įtaką, taikomas erdvinis atstumu paremtas požymių normalizavimas pagal (24), (25), (26) formules.

$$z'_i = \frac{z_i - \hat{\mu}_d}{\hat{\sigma}_d}, \quad (24)$$

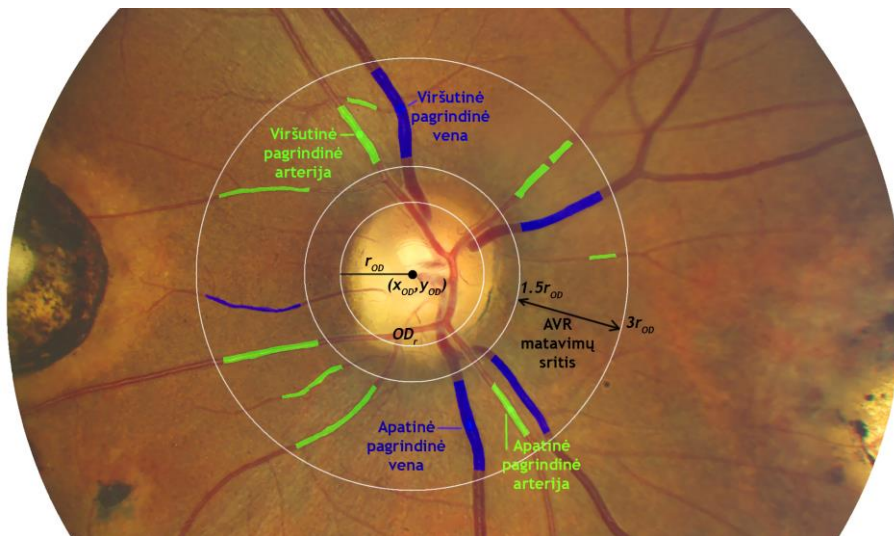
$$\hat{\mu}_d = \sum_{i \in \omega} \omega \frac{z_i}{d_i} / \sum_{i \in \omega} \omega \frac{1}{d_i}, \quad (25)$$

$$\hat{\sigma}_d^2 = \sum_{i \in \omega} \omega \left(\frac{z_i}{d_i} - \bar{z}_d \right) / \sum_{i \in \omega} \omega \frac{1}{d_i}, \quad (26)$$

čia $\hat{\mu}_d$ – požymių lokalus vidurkis, $\hat{\sigma}_d^2$ – požymių lokali dispersija. ω yra 10 artimiausių kraujagyslių aibė, d_i – Euklido atstumas tarp atitinkamų kraujagyslių dalių centrų.

Po erdvinio atstumu paremto normalizavimo požymiai naudojami kraujagyslėms klasifikuoti. Šiame etape naudojamas k -vidurkių klasterizavimo metodas, klasterizuojama į du klasterius. Atskirai klasterizuojamos viršutinės ir apatinės kraujagyslės OD_r centro atžvilgiu. Kadangi požymiams parinkta vieta yra šviesesnė arterijose nei venose, klasteris, kurio centro vidurkis yra didesnis, klasifikuojamas kaip arterija, o klasteris, kurio centro vidurkis mažesnis, klasifikuojamas kaip vena. Dvi didžiausios, po vieną iš skirtingų klasių, kraujagyslės laikomos pagrindine

arterija ir pagrindine vena. Atskirai parenkamos viršutinės ir apatinės kraujagyslės. Pagal parinktų kraujagyslių pločius apskaičiuojamos viršutinė ir apatinė AVR reikšmės. Vienas iš rezultatų paveikslukų pateiktas 36 pav. Klasifikavimo rezultatai ir lyginimas pateikti rezultatų skyriuje.



36 pav. Pagrindiniai AVR analizės elementai. Naudojamas vaizdas iš INSPIRE-AVR duomenų bazės (Niemeijer et al., 2011)

Pateikto metodo klasifikavimo tikslumas testuotas su trimis akies dugno vaizdų bazėmis. DRIVE (Staal et al., 2004) vaizdų bazė yra viena iš populiariausių akies dugno bazių, naudojamų metodams lyginti, tačiau ji jau pasenusi, o joje pateikti vaizdai yra mažos raiškos – 565×584 taškų. Šioje bazėje yra 40 akies dugno vaizdų. Ši bazė pasirinkta pademonstruoti metodo automatiniam prisiderinimui prie bet kokios, net ir labai mažos, raiškos vaizdų. Kita naudota vaizdų bazė yra INSPIRE-AVR (Niemeijer et al., 2011). Joje taip pat yra 40 akies dugno vaizdų, kurių raiška – 2394×2048 taškų. Kita testavimui naudota vaizdų bazė yra OPTO-AVR, kurioje vaizdai gauti sudėtingomis sąlygomis. Vaizdai gauti prieš fizinį apkrovimą, iš karto po jo ir praėjus 45 minutėms. Toks eksperimentas atliekamas norint mediciniškai patikrinti, ar stresas ir nuovargis daro įtaką AVR reikšmei. Šio tyrimo metu abiejų akių vaizdai nufotografuoti Optomed OY Smartscope M5 PRO mobiliąja akies dugno kamera. Šių vaizdų raiška – 1536×1152 taškų. Šioje bazėje iš viso yra 86 vaizdai.

4.3.5. Klasifikavimo rezultatai

Kraujagyslių išskyrimo tikslumas – tai teisingai nustatytų kraujagyslių santykis su visų kraujagyslių skaičiumi. Vertinimui matuojamos tik tos kraujagyslės, kurių plotis yra didesnis už $3 \cdot p_s$ ir tik iš AVR matavimų zonos. Taigi atmetamos labai plonos kraujagyslės. Tikslumui įvertinti apskaičiuojamas bendras klasifikavimo tikslumas, arterijos klasės specifiškumas (Sp), jautrumas (Se) ir plotas po ROC kreive (AUC). Šios statistinės reikšmės yra dažniausiai naudojamos kraujagyslių klasifikavimui lyginti. Rezultatai pateikti 6 lentelėje.

Lentelė 6. Kraujagyslių išskyrimo ir klasifikavimo statistikos.

Duomenų bazė	Kraujagyslių išskyrimo tikslumas	Kraujagyslių klasifikavimo statistikos			
		Tikslumas	Specifiškumas	Jautrumas	AUC
DRIVE (Staal et al., 2004)	0,942	0,854	0,9353	0,822	0,879
INSPIRE-AVR (Niemeijer et al., 2011)	0,882	0,859	0,8539	0,862	0,858
OPTO-AVR	0,904	0,835	0,8344	0,836	0,835

Kitų metodų rezultatai pateikti 7 lentelėje. Lyginant klasifikavimo rezultatus su kitų metodų rezultatais gaunamos labai panašios reikšmės. Atlikus klaidingo klasifikavimo atvejų analizę, matyti, kad pagrindinės klaidos yra dėl kraujagyslių persidengimų ir susikirtimų, taip pat dėl netolygaus apšvietimo. Peržiūrėjus visus klasifikavimui naudotus vaizdus, tik 15 kitų vaizdo objektų (artefaktų) klasifikuoti kaip kraujagyslės dėl kraujagyslių struktūrą primenančių atspindžių.

Lentelė 7. Lyginimui naudotų metodų tikslumo rezultatai.

Metodas	Duomenų bazė	Naudotas metodas	Naudoti požymiai	Klasifikavimo rezultatai
(Muramatsu et al., 2011)	DRIVE	LDA	Spalvų reikšmės ir kontrasto požymiai.	Tikslumas = 0,928, Se = 0,87
(Mirsharifa et al., 2013)	DRIVE	LDA	Spalvų reikšmės ir statistikos.	Tikslumas = 0,916

(Dashtbozorg et al., 2014)	DRIVE	Grafais parentas metodas su LDA.	Spalvų reikšmės ir statistikos.	Tikslumas = 0,883, Se = 0,91, Sp = 0,86
(Niemeijer et al., 2011)	INSIPRE-AVR	LDA.	Normalizuotos spalvų reikšmės ir statistikos.	AUC = 0,84
(Dashtbozorg et al., 2014)	INSIPRE-AVR	Grafais parentas metodas su LDA.	Spalvų reikšmės ir statistikos.	Tikslumas = 0,874, Se = 0,90, Sp = 0,84

AVR reikšmės įvertinimą palyginus su INSPIRE-AVR (Niemeijer et al., 2011) duomenimis, gauta vidutinė absoliutinė paklaida MAE=0,093. Palyginus AVR reikšmes su ekspertų matavimais, atliktais OPTO-AVR bazėje, gauta MAE=0,156 reikšmė.

4.3.6. Klasifikavimo lyginimas su įprastais metodais

Skyriuje 4.3.5 aprašymo tyrimo metu išskirtoms akies dugno kraujagyslėms klasifikuoti į arterijas ir venas buvo taikomas k-vidurkių klasterizavimo metodas. Šis metodas neturi mokymo proceso, o kiekvieno vaizdo kraujagyslės klasifikuojamos nepriklausomai nuo anksčiau klasifikavimui naudotų vaizdų. Visuose lyginimui naudotuose metoduose buvo taikytas LDA klasifikavimo metodas, priklausantis klasifikavimo su mokymu metodų grupei. Šiuose metoduose modeliui kurti naudojami mokymo duomenys. Prie mokymo duomenų priderintas modelis toliau yra naudojamas naujiems stebėjimas klasifikuoti. Šie metodai labai gerai klasifikuoja duomenis, kurie yra panašūs į mokymui naudotus duomenis.

Norint palyginti siūlomą metodą su klasifikavimo su mokymu metodais, vietoje k-vidurkių metodo taikyti LDA, SVM, K-NN ir DT metodai. Kiekvienas iš metodų buvo modeliuojamas su trimis skirtingomis vaizdų bazėmis atskirai. Kiekvienam iš metodų buvo sukurta po tris skirtingus modelius, po atskirą modelį kiekvienai vaizdų bazei. Mokymui buvo naudojama po pusę visų vaizdų, esančių vaizdų bazėse. Mokymui nepanaudotų vaizdų dalis buvo naudojama modeliams testuoti. Sukurti modeliai buvo testuojami ir su vaizdų bazėmis, kurių vaizdai nebuvo naudojami konkrečiam modeliui mokytį. 8 lentelėje pateikti skirtingų metodų klasifikavimo tikslumo rezultatai, nurodoma, su kuria vaizdų baze buvo atliekamas modeliavimas, o su kuria modelis naudotas testavimui. 9 lentelėje

pateikiamas skirtingų klasifikavimo metodų vidutinis klasifikavimo tikslumas, kai modeliuojama ir testuojama su ta pačia vaizdų baze ir kai modeliuojama ir testuojama su skirtingomis vaizdų bazėmis.

Lentelė 8. Rezultatai naudojant klasifikavimo su mokymu metodus.

Duomenų bazė		Klasifikavimo tikslumas (%)			
Modeliavimo	Testavimo	LDA	SVM	K-NN	DT
DRIVE	DRIVE	89,05	91,23	92,13	93,72
	INSIPRE-AVR	61,50	59,26	60,67	65,57
	OPTO-AVR	62,80	63,74	65,86	67,16
INSIPRE-AVR	INSIPRE-AVR	90,21	85,30	86,98	92,34
	DRIVE	80,95	66,02	87,50	79,61
	OPTO-AVR	84,11	80,91	80,58	79,16
OPTO-AVR	OPTO-AVR	88,56	86,39	84,45	89,09
	DRIVE	80,72	85,30	83,08	84,17
	INSIPRE-AVR	83,18	81,42	82,71	81,27

Lentelė 9. Vidutinis klasifikavimo tikslumas su skirtingais metodais.

Duomenų bazė		Vidutinis klasifikavimo tikslumas (%)			
Modeliavimo	Testavimo	LDA	SVM	K-NN	DT
Sutampa		89,28	87,64	87,85	91,72
Skiriasi		75,54	72,78	76,73	76,16

Iš 8 ir 9 lentelėse pateiktų rezultatų matome, kad taikant klasifikavimo su mokymu metodus, kai metodai mokomi ir testuojami su ta pačia įranga gautais vaizdais, pasiekiamas panašus ir net didesnis klasifikavimo tikslumas nei lyginimui naudotuose straipsniuose. Tačiau šiuos metodus apmokus su vaizdais iš vienos bazės ir naudojant klasifikavimui kitos bazės vaizdus, klasifikavimo tikslumas sumažėja. Kai kurių metodų, kai mokymui naudojama DRIVE duomenų bazė, tikslumas sumažėja daugiau kaip 20 %.

Remiantis pateiktais tyrimo rezultatais, klasifikavimui tikslinga taikyti LDA, SVM ar kitus klasifikavimo su mokymu metodus, kai analizuojami su ta pačia įranga ir panašiomis sąlygomis gauti vaizdai ir kai jau turime panašiam vaizdų rinkiniui apmokytą metodo modelį. Tačiau jei tyrimui naudojamų vaizdų bazė nėra žinoma, didesnis tikslumas pasiekiamas taikant klasifikavimo be mokymo metodus.

Šiame tyrime klasifikavimui naudoti požymiai normalizuoti taikant erdvinio atstumu paremtą normalizavimą pagal (24) formulę. Klasifikavimo su mokymu metodai buvo pritaikyti ir požymiams pritaikius nuo kraujagyslių išsidėstymo erdvėje nepriklausantį normalizavimą:

$$z'_i = \frac{z_i - \hat{\mu}}{\hat{\sigma}}, \quad (27)$$

čia $\hat{\mu}$ yra normalizuojamo požymio vidurkis, o $\hat{\sigma}$ yra normalizuojamo požymio dispersija. Šie įverčiai apskaičiuojami pagal visas klasifikuojamas kraujagysles iš vieno vaizdo. Gauti rezultatai pateikti 10 lentelėje.

Lentelė 10. Tyrimo rezultatai, kai požymiai normalizuojami nepriklausomai nuo objektų erdvinio išsidėstymo.

Duomenų bazė		Vidutinis klasifikavimo tikslumas (%)			
Modeliavimo	Testavimo	LDA	SVM	K-NN	DT
Sutampa		85,04	75,29	76,50	83,33
Skiriasi		72,18	74,98	73,42	66,88

Vietoje erdvinio atstumu paremto normalizavimo požymiams pritaikius įprastai naudojamą duomenų normalizavimo metodą gaunamas 6,25 % mažesnis bendras klasifikavimo tikslumas.

4.4. Skyriaus išvados

Akies dugno analizėje naudojamomis priemonėmis sukurtas ir išanalizuotas pradinis akies dugno kraujagyslių tyrimo metodas. Per tyrimą nustatyta, kad reikia mažinti metodo skirtingų etapų tarpusavio priklausomybę.

Atsižvelgiant į tyrimo rezultatus sukurtas automatizuotas akies dugno kraujagyslių matavimo metodas. Šiame metode naudojama erdvinė funkcija ir kiti statistiniai sprendimai. Atlikus tyrimą nustatyta, kad metodu atlikti matavimai statistiškai reikšmingai sutampa su ekspertų matavimais, kai naudojamas 0,95 reikšmingumo lygmuo. Lyginant matavimus gautas determinacijos koeficientas $R^2 = 0,88$.

Pasiūlytas visiškai automatinis akies dugno analizės metodas automatiškai atlieka kraujagyslių pločio matavimus, kraujagyslių klasifikavimą ir pagal gautą informaciją įvertina arterijų ir venų santykį. Šis parametras gali būti naudojamas ankstyvajai ligų diagnozei. Čia pasiūlyti nauji požymiai, paremti kraujagyslių erdvine informacija, kurie naudojami kraujagyslėms klasifikuoti. Požymiai normalizuoti į normalizavimą įtraukiant kraujagyslių erdvinę

informaciją. Taip sumažinama netolygaus apšvietimo įtaka. Kraujagyslių požymiai naudojami su k -vidurkių klasterizavimo metodu, bet šie požymiai gali būti klasifikuojami ir kitais klasifikavimo metodais.

Metodo veikimas testuotas su DRIVE, INSPIRE-AVR ir su OPTO-AVR akies dugno vaizdų bazėmis. Gautas kraujagyslių klasifikavimo tikslumas atitinkamoms bazėms yra lygus 0,854, 0,859 ir 0,835. Metodas yra ne toks tikslus kaip kiti panašūs metodai, bet yra pranašesnis dėl savo universalumo, adaptyvumo skirtingo dydžio vaizdams ir dėl to, kad jo nereikia papildomai derinti prie skirtingo tipo vaizdų.

Metoduose, kurie naudoti lyginimui, klasifikavimas atliekamas LDA metodu, kuriam reikia priderinti skirtingus modelius prie skirtingo tipo vaizdų, norint gauti siekiamą tikslumą. Atlikus tyrimą nustatyta, kad taikant LDA, SVM, K-NN ir DT klasifikavimo su mokymu metodus, metodų mokymui ir testavimui naudojama ta pati vaizdų bazė, kai kurių metodų klasifikavimo tikslumas viršija lyginimui naudotų metodų tikslumą. Tačiau kai metodų mokymui ir testavimui naudojamos skirtingos vaizdų bazės, klasifikavimo tikslumas vidutiniškai sumažėja 13 %, kai kuriais atvejais daugiau kaip 20 %. Šie metodai gali būti naudojami, kai tyrimams naudojama ta pati įranga ir vaizdai visada yra gaunami panašiomis sąlygomis. Tačiau šiuos metodus sudėtinga naudoti efektyviai, kai analizė turi būti atliekama automatiškai ir nežinant, kokio tipo vaizdai yra analizuojami. Siūlomo metodo atveju modelio derinimas nėra naudojamas.

Kai požymiai normalizuoti į normalizavimą įtraukiant kraujagyslių erdvinę informaciją, taikant klasifikavimo su mokymu metodus, klasifikavimo tikslumas padidėja vidutiniškai 6 %.

5. IŠVADOS IR REKOMENDACIJOS

1. Sukurtas klasifikavimo su mokymu SCRD metodas, kuris tampa pranašesnis už kitus panašius metodus dėl naudotos erdvinės informacijos. Pateiktas metodas naudojamas tada, kai klasifikuojamuose duomenyse yra erdvėje koreliuoto triukšmo. Triukšmo tyrimais nustatyta, kad metodas tampa pranašesnis nuo tada, kai triukšmas sudaro 75 % vaizdo informacijos.
2. Atlikus eksperimentus nustatyta, kad pasiūlyto metodo klasifikavimo tikslumas didėja, kai didėja erdvinės koreliacijos plotis α . Tuo tarpu įprastų klasifikavimo metodų (NNet, SVM, RF) tikslumas mažėja (kai α parametras padidėja nuo 10 iki 20, tikslumas sumažėjo 2 %).
3. Ištyrus kaimynų parinkimo būdus SCRD metodui, nustatyta, kad kai imama po keletą mokymo imties taškų iš kiekvienos klasės, tiksliau išskiriama vaizde esančio objekto struktūra, kai tam tikrose to objekto dalyse nėra mokymo imties taškų. Tai aktualu turint mažą mokymo imtį ir kai reikia išskirti plona struktūra pasižyminčius objektus.
4. SCRD metodo apibendrinimas sudaro galimybes naudoti metodą 3D vaizdams klasifikuoti. Klasifikavimo tikslumas trimatėje koordinatinių sistemoje siekia 91,5 %, kai triukšmas sudaro 75 % vaizdo informacijos. Šis išplėtotas metodas sudaro galimybes taikyti metodą medicininių MRT ir KT vaizdų atskiriems taškams klasifikuoti dviejų klasių atveju.
5. Darbe pasiūlytas skalės parametro apskaičiavimo ir taikymo būdas, kuris padeda spręsti akies dugno vaizdų analizės automatizavimo problemas susijusias su kintančia medicininių vaizdų raiška.
6. Pasiūlytas vaizdo profilio informacijos išskyrimo metodas, kuris padeda kurti adaptyvius ir lokaliai triukšmui atsparius kraujagyslių analizės metodus. Metodas pritaikytas akies dugno kraujagyslių matavimams, kurie sutampa su ekspertų matavimais (su 0,95 reikšmingumo lygmeniu, $R^2 = 0,88$).
7. Sukurtas automatinis AVR matavimams skirtų kraujagyslių klasifikavimo metodas. Metodas testuotas su trimis akies dugno vaizdų bazėmis be papildomos kiekvienos iš jų adaptacijos ir nekeičiant vaizdų raiškos (klasifikavimo tikslumo įverčiai: 0,854, 0,859 ir 0,835). Metode naudojami nauji pasiūlyti požymiai ir jų erdvinis normalizavimas, kuris sumažina netolygaus apšvietimo įtaką ir klasifikavimo tikslumą padidina vidutiniškai 6 %.

8. *AVR* matavimams skirtų kraujagyslių klasifikavime pritaikyti klasifikavimo su mokymu metodai (LDA, SVM, K-NN ir DT). Kai jų mokymui ir testavimui naudojama ta pati vaizdų bazė, kai kurių metodų klasifikavimo tikslumas viršija lyginimui naudotų metodų tikslumą. Tačiau kai metodų mokymui ir testavimui naudojamos skirtingos vaizdų bazės, klasifikavimo tikslumas vidutiniškai sumažėja 13 %.

LITERATŪROS SĄRAŠAS

1. Abiodun O. I., Jantan A., Omolara A. E., Dada K. V., Mohamed N. A., Arshad H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), p. e00938. doi:10.1016/j.heliyon.2018.e00938
2. Adem K. (2018). Exudate detection for diabetic retinopathy with circular Hough transformation and convolutional neural networks. *Expert Systems with Applications*, 114, p. 289–295. doi:10.1016/j.eswa.2018.07.053
3. Alghamdi H. S., Tang H. L., Waheeb S. A., Peto T. (2016). Automatic Optic Disc Abnormality Detection in Fundus Images: A Deep Learning Approach. *Proceedings of the Ophthalmic Medical Image Analysis Third International Workshop, OMIA 2016*, p. 17–24. doi:10.17077/omia.1042
4. Almotiri J., Elleithy K., Elleithy A. (2018). Retinal Vessels Segmentation Techniques and Algorithms: A Survey. *Applied Sciences*, 8(2), p. 155. doi:10.3390/app8020155
5. Atkinson P. M. (2004). Spatially weighted supervised classification for remote sensing. *International journal of applied earth observation and geoinformation*, 5, p. 277–291.
6. Atkinson P. M., Naser D. K. (2009). A geostatically weighted k-nn classifier for remote sensed imagery. *Geographical Analysis*, 42, p. 204–225.
7. Atkinson P., Lewis P. (2000). Geostatistical classification for remote sensing: an introduction. *Computers & Geosciences*, 26(4), p. 361–371. doi:10.1016/S0098-3004(99)00117-X
8. Balaguer A., Ruiz L. A., Hermsilla T., Recio J. A. (2010). Definition of a Comprehensive Set of Texture Semivariogram Features and Their Evaluation for Object-Oriented Image Classification. *Computers & Geosciences*, 36(2), p. 231–240. doi:10.1016/j.cageo.2009.05.003
9. Balkys G., Dzemyda G. (2012). Segmenting the eye fundus images for identification of blood vessels. *Mathematical Modelling and Analysis*, 17(1), p. 21–30. doi:10.3846/13926292.2012.644046

10. Bankhead P., Scholfield C. N., Geown J. G., Curtis T. M. (2012). Fast Retinal Vessel Detection and Measurement Using Wavelets and Edge Location Refinement. *PLOS ONE*, 7.
11. Benediktsson J. A., Palmason J. A., Sveinsson J. R. (2005). Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), p. 480–491. doi:10.1109/TGRS.2004.842478
12. Berberoglu S., Curran P. J., Lloyd C. D., Atkinson P. M. (2007). Texture Classification of Mediterranean Land Cover. *International Journal of Applied Earth Observation and Geoinformation*, 9(3), p. 322–334. doi:10.1016/j.jag.2006.11.004
13. Bock R., Meier J., Nyl L. G., Michelson G. (2010). Glaucoma risk index: automated glaucoma detection from color fundus images. *Medical Image Analysis*, 14(3), p. 471–481.
14. Breiman L. (2001). Random forests. *Mach. Learn.*, 45(1), p. 5–32.
15. Buteikienė D., Paunksnis A., Barzdžiukas V., Bernatavičienė J., Marcinkevičius V., Treigys, P. (2012). Assessment of the optic nerve disc and excavation parameters of interactive and automated parameterization methods. *Informatica*, 23(3), p. 335–355.
16. Chollet F. (2018). *Keras*. Paimta 2018 iš Keras: <https://keras.io/>
17. Clausi D. A., Zhao Y. (2002). Rapid extraction of image texture by co-occurrence using a hybrid data structure. *Computers & Geosciences*, 28(6), p. 763–774. doi:10.1016/S0098-3004(01)00108-X
18. Comber A. J. (2013). Geographically weighted methods for estimating local surfaces of overall, user and producer accuracies. *Remote Sensing Letters*, 4, p. 373–380.
19. Cressie N. (1993). *Statistics for Spatial Data revised edition*. New York: Wiley.
20. Dashtbozorg B., Mendonca A. M., Campilho A. (2014). An Automatic Graph-Based Approach for Artery/Vein Classification in Retinal Images. *IEEE Transactions on Image Processing*, 23(3), p. 1073–1083.
21. Decencière E., Zhang X., Cazuguel G., Lay B., Cochener B., Ordonez R. (2014). Feedback on a publicly distributed database: the

- Messidor database. *Image Analysis & Stereology*, 33(3), p. 231–234. doi:10.5566/ias.1155
22. Dučinskas K. (2009). Approximation of the expected error rate in classification of the Gaussian random field observations. *Statistics and Probability Letters*, 79.
 23. Dučinskas K. (2011). Error rates in classification of multivariate Gaussian random field observation. *Lithuanian Mathematical Journal*, 51(4), p. 477–485.
 24. Dučinskas K., Stabingienė L. (2011). Expected bayes error rate in supervised classification of spatial gaussian data. *Informatica*, 22(3), p. 371–381.
 25. Dučinskas K., Stabingienė L., Stabingis G. (2011). Image classification based on Bayes discriminant functions. *Procedia Environ. Sci., Spatial Statistics 2011 – Mapping Global Change*, 7, p. 218–223.
 26. Dzemyda G., Kurasova O., Žilinskas J. (2008). *Daugiamačių duomenų vizualizavimo metodai*. Vilnius: Mokslo aidai.
 27. Fairfield J. (1990). Toboggan contrast enhancement for contrast segmentation., p. 712–716.
 28. Fratello M., Tagliaferri R. (2019). Decision Trees and Random Forests. Esantis M. G. Shoba Ranganathan (Mont.), *Encyclopedia of Bioinformatics and Computational Biology*, p. 374–383. Academic Press. doi:10.1016/B978-0-12-809633-8.20337-3
 29. Fraz M. M., Rudnicka A. R., Owen C. G., Strachan D. P., Barman S. A. (2014). Automated arteriole and venule recognition in retinal images using ensemble classification. *2014 International Conference on Computer Vision Theory and Applications (VISAPP)*, 3, p. 194–202.
 30. Fraz P. R., Hoppe A., Uyyanonvara B., Rudnicka A. R., Owen C. G., Barman S. A. (2012). Blood vessel segmentation methodologies in retinal images a survey. *Comput. Methods Programs Biomed*, 108, p. 407–433.
 31. Fukushima K. (1980). A self-organizing neural network model for a mechanism of pattern recognition. *Biological Cybernetics*, 36(4), p. 193–202. doi:10.1007/BF00344251

32. Gargeya R., Leng T. (2017). Automated Identification of Diabetic Retinopathy Using Deep Learning. *Ophthalmology*, 124(7), p. 962–969. doi:10.1016/j.ophtha.2017.02.008
33. Gonzalez R. C., Woods R. E. (2018). *Digital Image Processing* (4 leid.). Pearson.
34. Guo L., Chen L., Chen C. P., Zhou J. (2018). Integrating guided filter into fuzzy clustering for noisy image segmentation. *Digital Signal Processing*, 83, p. 235–248. doi:10.1016/j.dsp.2018.08.022
35. Guo X., Huang X., Zhang L. (2014). Three-Dimensional Wavelet Texture Feature Extraction and Classification for Multi/Hyperspectral Imagery. *IEEE Geoscience and Remote Sensing Letters*, 11(12), p. 2183–2187. doi:10.1109/LGRS.2014.2323963
36. Haralick R. M. (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67, p. 786–804.
37. Hoover A., Kouznetsova V., Goldbaum M. (2000). Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. *IEEE Transactions on Medical Imaging*, 19(3), p. 203–210. doi:10.1109/42.845178
38. Huang X., Liu X., Zhang L. (2014). A Multichannel Gray Level Co-Occurrence Matrix for Multi/Hyperspectral Image Texture Representation. *Remote Sensing*, 6(9), p. 8424–8445. doi:10.3390/rs6098424
39. Yosinski J., Clune J., Bengio Y., Lipson H. (2014). How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 27, p. 3320–3328.
40. Jain A. K., Duin P. W., Mao J. (2000). Statistical pattern recognition: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1), p. 4–37.
41. Ji S., Xu W., Yang M., Yu K. (2013). 3D Convolutional Neural Networks for Human Action Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(1), p. 221–231. doi:10.1109/TPAMI.2012.59

42. Kanagasingam Y., Bhuiyan A., Abrmoff M. D., Smith R. T., Goldschmidt L., Wong T. Y. (2014). Progress on retinal image analysis for age related macular degeneration. *Progress in Retinal and Eye Research*, 38, p. 20-42.
43. Kanski J. (2007). *Clinical Ophthalmology* (6 leid.). London: Elsevier Health Sciences.
44. Kauppi T., Kämäräinen J.-K., Lensu L., Kalesnykiene V., Sorri I., Uusitalo H., Kälviäinen H. (2013). Constructing Benchmark Databases and Protocols for Medical Image Analysis: Diabetic Retinopathy,. *Computational and Mathematical Methods in Medicine*, 2013. doi:10.1155/2013/368514
45. Knudtson M. D., Lee K. E., Hubbard L. D., Wong T. Y., Klein R., Klein B. E. (2003). Revised formulas for summarizing retinal vessel diameters. *Current Eye Research*, 27(3), p. 143–149.
46. Kondermann C., Kondermann D., Yan Y. (2007). Blood vessel classification into arteries and veins in retinal images. *Proceedings of SPIE*. doi: 10.1117/12.708469
47. Kort E. (2015). *rtiff – R package*. Paimta 2018 iš <https://cran.r-project.org/web/packages/rtiff/>
48. Krishnan S., Athavale Y. (2018). Trends in biomedical signal feature extraction. *Biomedical Signal Processing and Control*, 43, p. 41–63. doi:10.1016/j.bspc.2018.02.008
49. Krizhevsky A., Sutskever I., Hinton G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 1, p. 1097–1105.
50. LeCun Y., Bengio Y., Hinton G. (2015). Deep learning. *Nature*, 521, p. 436–444. doi:10.1038/nature14539
51. Li H., Hsu, W., Lee M. L., Wang H. (2003). Piecewise Gaussian Model for Profiling and Differentiating Retinal Vessels. *Proceedings 2003 International Conference on Image Processing (Cat. No.03CH37429)*, 1, p. I-1069–1072.

52. Li M., Zang S., Zhang B., Li S., Wu C. (2014). A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information. *European Journal of Remote Sensing*, 47, p. 389–411.
53. Li X., Wee W. G. (2014). Retinal vessel detection and measurement for computer-aided medical diagnosis. *Journal of Digital Imaging*, 27(1), p. 120–132.
54. Lippmann R. P. (1987). An introduction to computing with neural nets. *IEEE ASSP Magazine*, 2, p. 4–22.
55. Liskowski P., Krawiec K. (2016). Segmenting Retinal Blood Vessels With Deep Neural Networks. *IEEE Transactions on Medical Imaging*, 11, p. 2369–2380. doi:10.1109/TMI.2016.2546227
56. Liu J. G., Mason P. J. (2009). *Essential image processing and GIS for remote sensing*. UK: Wiley-Blackwell.
57. Mahdavinejad M. S., Rezvan M., Barekatin M., Adibi P., Barnaghi P., Sheth A. P. (2018). Machine learning for internet of things data analysis: a survey. *Digital Communications and Networks*, 4(3), p. 161–175. doi:10.1016/j.dcan.2017.10.002
58. Maillard P. (2003). Comparing Texture Analysis Methods through Classification. *Photogrammetric Engineering & Remote Sensing*, 69(4), p. 357–367. doi:10.14358/PERS.69.4.357
59. McCulloch W. S., Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), p. 115–133. doi:115–133
60. Melinscak M., Prentasic P., Loncaric S. (2015). Retinal vessel segmentation using deep neural networks. In *Proceedings of the 10th International Conference on Computer Vision Theory and Applications (VISIGRAPP 2015)*, p. 577–582.
61. Mendonca A., Dashtbozorg B., Campilho A. (2013). Segmentation of the vascular network of the retina. *Image Analysis and Modeling in Ophthalmology*.
62. Myint S. W., Lam N. S.-N., Tyler J. M. (2004). Wavelets for Urban Spatial Feature Discrimination. *Photogrammetric Engineering & Remote Sensing*, 70(7), p. 803–812. doi:10.14358/PERS.70.7.803

63. Miri M., Amini Z., Rabbani H., Kafieh R. (2017). A Comprehensive Study of Retinal Vessel Classification Methods in Fundus Images. *Journal of Medical Signals & Sensors*, 7(2), p. 59–70.
64. Mirsharifa Q., Tajeripoura F., Pourreza H. (2013). Automated characterization of blood vessels as arteries and veins in retinal images. *Computerized Medical Imaging and Graphics*, 37, p. 607–617.
65. Morgan A. J., Hosking S. L. (2007). Non-invasive vascular impedance measures demonstrate ocular vasoconstriction during isometric exercise. *British Journal of Ophthalmology*, 91(3), p. 385–390.
66. Morkunas M., Treigys P., Bernataviciene J., Laurinavicius A., Korvel G. (2018). Machine Learning Based Classification of Colorectal Cancer Tumour Tissue in Whole-Slide Images. *Informatika*, 29(1), p. 75–90.
67. Mun J., Jang Y., Nam Y., Kim J. (2018). Edge-enhancing bi-histogram equalisation using guided image filter. *Journal of Visual Communication and Image Representation*. doi:10.1016/j.jvcir.2018.12.037
68. Mura M. D., Benediktsson J. A., Waske B., Bruzzone L. (2010). Morphological Attribute Profiles for the Analysis of Very High Resolution Images. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10), p. 3747–3762. doi:10.1109/TGRS.2010.2048116
69. Muramatsu C., Hatanaka Y., Iwase T., Hara T., Fujita H. (2011). Automated selection of major arteries and veins for measurement of arteriolar-to-venular diameter ratio on retinal fundus images. *Computerized Medical Imaging and Graphics*, 35, p. 472–480.
70. Neverova N., Wolf C., Taylor G. W., Nebout F. (2016). ModDrop: adaptive multi-modal gesture recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(8), p. 1692–1706.
71. Ng W., Dorado A., Yeung D., Pedrycz W., Izquierdo E. (2007). Image classification with the use of radial basis function neural networks and the minimization of the localized generalization error. *Pattern Recognition*, 40, p. 19–32.

72. Nguyen U. T., Bhuiyan A., Park L. A., Ramamohanarao K. (2013). An effective retinal blood vessel segmentation method using multi-scale line detection. *Pattern Recognition*, 46, p. 703–715.
73. Niemeijer M., Abramoff M., van Ginneken B. (2009). Fast detection of the optic disc and fovea in color fundus photographs. *Medical Image Analysis*, 13(6), p. 859–870.
74. Niemeijer M., Gupta P., Ginneken B. V., Folk J., Abramoff M. (2011). Automated Measurement of the Arteriolar-To-Venular Width Ratio in Digital Color Fundus Photographs. *IEEE Transactions on Medical Imaging*, 30(11), p. 1941–1950.
75. Odstrcilik J., Kolar R., Budai A., Hornegger J., Jan J., Gazarek J., Angelopoulou E. (2013). Retinal vessel segmentation by improved matched filtering: evaluation on a new high resolution fundus image database. *IET Image Processing*, 7(4), p. 373–383.
76. Oliver M. A., Webster R. (1989). A geostatistical basis for spatial weighting in multivariate classification. *Mathematical geology*, 21, p. 15–35.
77. Öztürk Ş., Akdemir B. (2018). Application of Feature Extraction and Classification Methods for Histopathological Image using GLCM, LBP, LBGLCM, GLRLM and SFTA. *Procedia Computer Science*, 132, p. 40–46. doi:10.1016/j.procs.2018.05.057
78. Pachiyappan A., Das U., Murthy T., Tatavarti R. (2012). Automated diagnosis of diabetic retinopathy and glaucoma using fundus and OCT images. *Lipids in Health and Disease*, p. 11–73.
79. Pant T., Singh D., Srivastava T. (2010). Advanced fractal approach for unsupervised classification of SAR images. *Advances in Space Research*, 45(11), p. 1338–1349. doi:10.1016/j.asr.2010.01.008
80. Prasath V. B. (2017). Quantum Noise Removal in X-Ray Images with Adaptive Total Variation Regularization. *Informatica*, 28(3), p. 505–515.
81. R Core Team. (2018). R: A Language and Environment for Statistical Computing, . *R Foundation for Statistical Computing*. Viena, Austria. Nuskaityta iš <https://www.r-project.org/>

82. Ravishankar S., Jain A., Mittal A. (2009). Automated feature extraction for early detection of diabetic retinopathy in fundus images. *Computer Vision and Pattern Recognition (CVPR 2009. IEEE Conference)*.
83. Renukalatha S., Suresh K. V. (2018). A review on biomedical image analysis. *Biomedical Engineering: Applications, Basis and Communications*, 30(4).
84. Ribeiro P. J. (2016). *geoR – R programos paketas*. Imta 2018 m. iš <https://cran.r-project.org/web/packages/geoR/>
85. Schlather M. (2017). R package: Random fields. Imta 2018 m. iš <https://cran.r-project.org/web/packages/RandomFields/>
86. Serra J. (1986). Introduction to mathematical morphology. *Computer Vision, Graphics, and Image Processing*, 35(3), p. 283–305. doi:10.1016/0734-189X(86)90002-2
87. Serra J. (2008). Advances in Mathematical Morphology: Segmentation. *Advances in Imaging and Electron Physics*, 150, p. 185–219. doi:10.1016/S1076-5670(07)00004-3
88. Shen L., Zhu Z., Jia S., Zhu J., Sun Y. (2013). IEEE Geoscience and Remote Sensing Letters. *Discriminative Gabor Feature Selection for Hyperspectral Image Classification*, 10(1), p. 29–33. doi:10.1109/LGRS.2012.2191761
89. Shi M., Healey G. (2003). Hyperspectral texture recognition using a multiscale opponent representation. *IEEE Transactions on Geoscience and Remote Sensing*, 41(5), p. 1090–1095. doi:10.1109/TGRS.2003.811076
90. Sim D. A., Keane P. A., Tufail A., Egan C. A., Aiello L. P., Silva P. S. (2015). Automated retinal image analysis for diabetic retinopathy in telemedicine. *Current Diabetes Reports* 15:14. doi:10.1007/s11892-015-0577-6
91. Soares J., Leandro J., Cesar R., Jelinek H., Cree M. (2006). Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification. *IEEE Transactions on Medical Imaging*, 25(9), p. 1214–1222.

92. Soille P., Pesaresi M. (2002). Advances in mathematical morphology applied to geoscience and remote sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 40(9), p. 2042–2055. doi:10.1109/TGRS.2002.804618
93. Staal J., Abramoff M., Niemeijer M., Viergever M. A., Ginneken B.V. (2004). Ridge based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging*, 23, p. 501–509.
94. Stabingienė L. (2012). Classification of the real remotely sensed image covered with clouds. *Lietuvos matematikos rinkinys. LMD darbai*, 53, p. 117–122.
95. Stabingienė L. (2012). *Vaizdų analizė naudojant Bajeso diskriminantines funkcijas*. Vilnius: Vilniaus Universitetas.
96. Stabingienė L., Stabingis G., Dučinskas K. (2010). Comparison of linear discriminant functions in image classification. *Lietuvos matematikos rinkinys. LMD darbai*, 51, p. 227–231.
97. Stabingienė L., Stabingis G., Dučinskas K. (2011). Comparison of the classification methods for the images modeled by Gaussian random fields. *Lietuvos matematikos rinkinys. LMD darbai*, 52, p. 200–204.
98. Stabingis G. (2016). Spatial classification rule with distance in three dimensional space. *Lietuvos matematikos rinkinys. Proc. LMS, Ser. A*, 57, p. 81–85.
99. Stabingis G., Stabingienė L. (2014). Application of spatial classification rules for remotely sensed images. *Lietuvos matematikos rinkinys. Proc. of the Lithuanian Mathematical Society, Ser. B*, 55, p. 63–67.
100. Stabingis G., Stabingienė, L. (2015). Neighborhood scheme selection for classification with SCR method. *Lietuvos matematikos rinkinys. Proc. LMS, Ser. A*, 56, p. 101–106.
101. Stabingis G., Bernatavičienė J., Dzemyda G., Imbrasienė D., Paunksnis A. (2016). Automated Classification of Arteries and Veins in the Retinal Blood Vasculature. *Computer data analysis and modeling. Theoretical & Applied Stochastics. Proceedings 11th International Conference*, p. 64–67.

102. Stabingis G., Bernatavičienė J., Dzemyda G., Paunksnis A., Stabingienė L., Treigys P., Vaičaitienė R. (2018). Adaptive eye fundus vessel classification for automatic artery and vein diameter ratio evaluation. *Informatica*, 29(4), p. 757–771.
103. Stabingis G., Bernatavičienė J., Dzemyda G., Paunksnis A., Treigys P., Vaičaitienė R., Stabingienė L. (2017). Automatization of eye fundus vessel width measurements. *VipIMAGE 2017, Lecture Notes in Computational Vision and Biomechanics*, 27, p. 787–796.
104. Stabingis G., Dučinskas K., Stabingienė L. (2014). Comparison of spatial classification rules with different conditional distributions of class label. *Nonlinear Analysis. Modelling and Control*, 19(1), p. 109–117.
105. Sun C., Wang J. J., Mackey D. A., Wong T. Y. (2009). Retinal vascular caliber: Systemic, environmental, and genetic associations. *Survey of Ophthalmology*, 54(1), p. 74–95.
106. Sun W. (2006). Three New Implementations of the Triangular Prism Method for Computing the Fractal Dimension of Remote Sensing Images. *Photogrammetric Engineering & Remote Sensing*, 72(4), p. 373–382. doi:10.14358/PERS.72.4.373
107. Switzer P. (1980). Extensions of linear discriminant analysis for statistical classification of remotely sensed satellite imagery. *Mathematics in Geology*, 12(4), p. 367–376.
108. Taigman Y., Yang M., Ranzato M., Wolf L. (2014). DeepFace: Closing the Gap to Human-Level Performance in Face Verification. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, p. 1701–1708. doi:10.1109/CVPR.2014.220
109. Tan J. H., Fujita H., Sivaprasad S., Bhandary S. V., Rao A. K., Chua K. C., Acharya U. R. (2017). Automated segmentation of exudates, haemorrhages, microaneurysms using single convolutional neural network. *Information Sciences*, 420, p. 66–76. doi:10.1016/j.ins.2017.08.050
110. Tobler W. (1970). A computer movie simulating urban growth in Detroit region. *Economic Geography*, 46, p. 234–240.

111. Treigys P., Dzemyda G., Barzdžiukas V. (2008). Automated positioning of overlapping eye fundus images. *Computational Science – ICCS 2008. ICCS 2008. Lecture Notes in Computer Science*, 5101, p. 770–779.
112. Treigys P., Šaltenis V., Dzemyda G., Barzdžiukas V., Paunksnis A. (2008). Automated optic nerve disc parameterization. *Informatica*, 19(3), p. 403–420.
113. Triwijoyo B. K., Budiharto W., Abdurachman E. (2017). The Classification of Hypertensive Retinopathy using Convolutional Neural Network. *Procedia Computer Science*, 116, p. 166–173. doi:10.1016/j.procs.2017.10.066
114. Troya-Galvis A., Gañçarski P., Berti-Équille L. (2018). Remote sensing image analysis by aggregation of segmentation-classification collaborative agents. *Pattern Recognition*, 73, p. 259–274. doi:10.1016/j.patcog.2017.08.030
115. Tsai F., Lai J. (2013). Feature Extraction of Hyperspectral Image Cubes Using Three-Dimensional Gray-Level Cooccurrence. *IEEE Transactions on Geoscience and Remote Sensing*, 51(6), p. 3504–3513. doi:10.1109/TGRS.2012.2223704
116. Wang L., Shi C., Diao C., Ji W., Yin D. (2016). A survey of methods incorporating spatial information in image classification and spectral unmixing. *International Journal of Remote Sensing*, 37(16), p. 3870–3910. doi:10.1080/01431161.2016.1204032
117. Wang M. F., Fernandez-Gonzalez R. (2017). (Machine-)Learning to analyze in vivo microscopy: Support vector machines. *Biochimica et Biophysica Acta (BBA) – Proteins and Proteomics*, 1865(11), p. 1719–1727. doi:10.1016/j.bbapap.2017.09.013
118. Wang Q., Ma L., Gao Q., Li Y., Huang Y., Liu Y. (2017). Adaptive maximum margin analysis for image recognition. *Pattern Recognition*, 61, p. 339–347. doi:10.1016/j.patcog.2016.07.025
119. Wei B., Zhao Z., Peng X. (2011). Spatial Information Based Medical Image Registration using Mutual Information. *Journal of Multimedia*, 6, p. 236–243, doi:10.4304/jmm.6.3.236-243

120. Wiesmann D., Quinn D. (2016). *rasclass: Supervised Raster Image Classification*. Imta 2018 m. iš The Comprehensive R Archive Network: <https://cran.r-project.org/web/packages/rasclass/>
121. Wang X., Matsakis P., Trick L., Nonnecke B., Veltman M. (2008) A Study on how Humans Describe Relative Positions of Image Objects. *Headway in Spatial Data Handling. Lecture Notes in Geoinformation and Cartography*. p. 1–18, Springer, doi:10.1007/978-3-540-68566-1_1
122. Woods R. P. (2009), Registration, *Handbook of Medical Image Processing and Analysis (Second Edition)*, p. 495–497, Academic Press, doi: 10.1016/B978-012373904-9.50038-6.
123. Zhang G., Jiang S., Yang Z., Gong L., Ma X., Zhou Z., Liu Q. (2018). Automatic nodule detection for lung cancer in CT images: A review. *Computers in Biology and Medicine*, 103, p. 287–300. doi:10.1016/j.compbiomed.2018.10.033
124. Zhang K., Huang D., Zhang B., Zhang D. (2017). Improving texture analysis performance in biometrics by adjusting image sharpness. *Pattern Recognition*, 66, p. 16–25. doi:10.1016/j.patcog.2016.11.025
125. Zhang Z., Yin F. S., Liu J., Wong W. K., Tan N. M., Lee B. H., Wong T. Y. (2010). ORIGA-light: An online retinal fundus image database for glaucoma analysis and research. *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*, p. 3065–3068. doi:10.1109/IEMBS.2010.5626137

AUTORIAUS PUBLIKACIJŲ SĄRAŠAS DISERTACIJOS TEMA

Straipsniai periodiniuose moksliniuose leidiniuose

1. **Giedrius Stabingis**, Kęstutis Dučinskas, Lijana Stabingienė, Comparison of spatial classification rules with different conditional distributions of class label, *Nonlinear Analysis: Modeling and Control*, 2014, Volume 19, No 1, p. 109–117, MII, Vilnius. ISSN 1392-5113.
2. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, Lijana Stabingienė, Povilas Treigys, Ramutė Vaičaitienė, Adaptive eye fundus vessel classification for automatic artery and vein diameter ratio evaluation, *Informatica*, 2018, Volume 29, No. 4, p. 757–771.

Straipsniai konferencijų mokslinėje medžiagoje

1. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, Povilas Treigys, Ramutė Vaičaitienė, Lijana Stabingienė, Automatization of eye fundus vessel width measurements, *VipIMAGE 2017, Lecture Notes in Computational Vision and Biomechanics*, Volume 27, p. 787–796, 2017. Springer.
2. **Giedrius Stabingis**, Spatial classification rule with distance in three dimensional space, *Lietuvos matematikos rinkinys. Proc. LMS, Ser. A*, 2016, Vol. 57. p. 81–85, ISSN 0132-2818.
3. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Daiva Imbrasienė, Alvydas Paunksnis, Automated Classification of Arteries and Veins in the Retinal Blood Vasculature, *Computer data analysis and modeling. Theoretical & Applied Stochastics. Proceedings 11th International Conference*, 2016, p. 64–67. Minsk, Belarus.
4. **Giedrius Stabingis**, Lijana Stabingienė, Neighborhood scheme selection for classification with SCRD method, *Lietuvos matematikos rinkinys. Proc. LMS, Ser. A*, 2015, Vol. 56, p. 101–106. ISSN 0132-2818.
5. **Giedrius Stabingis**, Lijana Stabingienė, Application of spatial classification rules for remotely sensed images, *Lietuvos matematikos rinkinys. Proc. of the Lithuanian Mathematical Society, Ser. B*, 2014, Vol. 55, p. 63–67. ISSN 0132-2818.

Santraukos konferencijų leidiniuose

1. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, Povilas Treigys, Ramutė Vaičaitienė, Lijana Stabingienė. Automatic Artery Vein Ratio Measurements in Eye Fundus Images. *Data Analysis Methods for Software Systems. 9th International Workshop*. Druskininkai, Lietuva. 2017.
2. **Giedrius Stabingis**, Jolita Bernatavičienė, Povilas Treigys, Alvydas Paunksnis, Ramutė Vaičaitienė, Viktor Medvedev. Automated Blood Vessels Diameter Measurement in Eye Fundus Images. *Data Analysis Methods for Software Systems. 8th International Workshop*. Druskininkai, Lietuva. 2016.
3. Jolita Bernatavičienė, Gintautas Dzemyda, Alvydas Paunksnis, **Giedrius Stabingis**, Povilas Treigys. Automated Blood Vessel Detection and Pathological Changes Identification in Eye Fundus Images. *EURO 2016 - 28th European Conference on Operational Research*. Poznanė, Lenkija. 2016.
4. **Giedrius Stabingis**, Jolita Bernatavičienė, Gintautas Dzemyda, Daiva Imbrasienė, Alvydas Paunksnis, Viktorija Slavinskytė, Povilas Treigys. Automated Blood Vessel Detection and Characteristic Evaluation in Eye Fundus Images. *Data Analysis Methods for Software Systems. 7th International Workshop*. Druskininkai, Lietuva. 2015.
5. **Giedrius Stabingis**, Lijana Stabingienė. The influence of noise level to the accuracy of supervised classification methods. *Data Analysis Methods for Software Systems. 6th International Workshop*. Druskininkai, Lietuva. 2014.
6. Lijana Stabingienė, **Giedrius Stabingis**. The influence of noise level to the accuracy of supervised classification methods. *1st international conference on high performance computing and mathematical modelling*. Liepoja, Latvija. 2013.

Giedrius Stabingis

STATISTINIAI SPRENDIMAI ERDVINEI INFORMACIJAI
SKAITMENINIUOSE VAIZDUOSE

Daktaro disertacija

Gamtos mokslai

Informatika (N 009)

Redaktorė Jorūnė Rimeisytė – Nekrašienė

UŽRAŠAMS

Vilniaus universiteto leidykla
Saulėtekio al. 9, LT-10222 Vilnius
El. p. info@leidykla.vu.lt,
www.leidykla.vu.lt
Tiražas 20 egz.