



**KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS**

Lukas Artūras Gudas

**DIRBTINIO INTELEKTO METODŲ TAIKYMAS ĮVAIRIŲ
DEFEKTŲ ATPAŽINIMUI**

Baigiamasis magistro projektas

Vadovas

Doc. dr. Vidas Raudonis

KAUNAS, 2017

KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS
AUTOMATIKOS KATEDRA

**DIRBTINIO INTELEKTO METODŲ TAIKYMAS ĮVAIRIŲ
DEFEKTŲ ATPAŽINIMUI**

Baigiamasis magistro projektas
Valdymo technologijos (kodas 621H66001)

Vadovas

(parašas) Doc. dr. Vidas Raudonis
(data)


Recenzentas

(parašas) Prof. dr. Rimvydas Simutis
(data)

Projektą atliko

(parašas) Lukas Artūras Gudas
(data)

KAUNAS, 2017



KAUNO TECHNOLOGIJOS UNIVERSITETAS

(Fakultetas)

(Studento vardas, pavardė)

(Studijų programos pavadinimas, kodas)

Baigiamojo projekto „Dirbtinio intelekto metodų taikymas įvairių defektų atpažinimui“

AKADEMINIO SAŽNINGUMO DEKLARACIJA

20 ____ m. _____ d.
Kaunas

Patvirtinu, kad mano **Luko Artūro Gudo** baigiamasis projektas tema „Dirbtinio intelekto metodų taikymas įvairių defektų atpažinimui“ yra parašytas visiškai savarankiškai, o visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

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

(vardą ir pavardę įrašyti ranka)

(parašas)

Gudas, Lukas Artūras. Dirbtinio intelekto metodų taikymas įvairių defektų atpažinimui. *Valdymo sistemų magistro* baigiamasis projektas / vadovas doc. dr. Vidas Raudonis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas, Automatikos katedra.

Mokslų kryptis ir sritis: Elektros ir elektronikos inžinerija, Technologiniai mokslai

Reikšminiai žodžiai: *defektai, vaizdai, analizė, vienos klasės, klasifikavimas, matlab.*

Kaunas, 2017. 55 p.

SANTRAUKA

Darbe apžvelgiami įvairūs lygių paviršių defektų aptikimo būdai. Tiriamojoje dalyje bandomi įvairūs vienos klasės klasifikavimo metodai, nes tai padeda išvengti problemos, kai reikia susirinkti pakankamą defektų biblioteką. Aptariamas vaizdų paruošimas klasifikavimui – filtravimas ir rašto atvaizdavimas keliais skaitiniais parametrais. Metodų apmokymams išbandomi vaizdų raštų parametrų ištraukimo algoritmai. Pateikiamos išvados dėl geriausių rezultatų parodžiusio klasifikatoriaus ir geriausiai tinkamų vaizdo rašto parametrų. Prieduose pateikiama plokščių pavyzdžiai. (santraukos tekstas iki 5000 spaudos ženklų (su tarpais))

Gudas, Lukas Artūras. Application of Artificial Intelligence Methods for the Recognition of Different Defects: *Control systems master's thesis in Control Technologies* / supervisor assoc. dr. Vidas Raudonis. Kaunas University of Technology, Faculty of Electrical and Electronics Engineering, department of Automation

Research area and field: Electrical and Electronics Engineering, Technological Sciences

Key words: defects, images, analysis, one-class, classification, matlab

Kaunas, 2017. 55 p.

SUMMARY

In this work similar area articles are reviewed. In the research part it is chosen to use one-class classification, because it helps to avoid the problem of gathering the library of defects, since there can be unforeseen types of defects. Few decisions are made for preprocessing the images. In this thesis 11 feature extraction parameters are tried for use in image classification. According to the results the best classifier is chosen with the most suitable extracted features.

(summary text up to 5000 characters (with spaces))

Turinys

Santrumpų žodynas	7
Įvadas.....	8
1. Metodų apžvalga.....	9
1.1. Dviejų pakopų medienos defektų atpažinimas	9
1.2. Medienos defektų atpažinimas naudojantis dirbtiniais neuroniniais tinklais	10
1.3. Defektų detekcija naudojantis Fuzzy skirstymą pagal taisykles	12
1.4. Medžiagų su tekstūros paviršiumi defektų detekcija naudojantis Gaboro filtru	13
1.5. Plieno paviršiaus defektų detekcija pagrįsta dirbtiniais neuroniniais tinklais ir morfologija	15
1.6. Realaus laiko vizualinių anomalijų detekcijos sistemos įdiegimas	17
1.7. Neprižiūrima paviršiaus defektų detekcija: dviejų žingsnių metodas	19
1.8. Objekto paviršių anomalijų aptikimas išnaudojant retumą	19
1.9. Realaus laiko algoritmas skirtas aliuminio paviršiaus defektų aptikimui	20
1.10. Paviršiaus defektų detekcija naudojantis perskaičiuojamo slenksčio metodu.....	21
1.11. Apibendrinimas.....	22
2. Metodika	22
2.1. Duomenų surinkimas.....	22
2.2. Pradinis duomenų apdorojimas	22
2.3. Plokščių požymių įvertinimas	23
2.4. Klasifikatorių apmokymas.....	25
3. Eksperimentai	30
3.1. Tyrimas.....	30
3.2. Rezultatai.....	31
Išvados.....	39
Literatūros sąrašas	40
Priedai.....	43

Santrumpų žodynas

CR2 – Canon fotoaparatų vaizdų išsaugojimo formatas.

RGB – raudona, žalia, mėlyna. Skaitmeniniuose vaizduose naudojama spalvų sistema.

HSV – Atspalvis, spalvos sodrumas, šviesumas. Skaitmeniniuose vaizduose naudojama spalvų sistema.

SOM – Self-organizing map data. Klasifikatoriaus tipas.

GLRLM – Gray Level Run Length Matrix. Matrica sudaryta iš įvairių parametrų, gautų analizuojant vaizdą.

PHOT – fazės transformacija (*angl.* Phase Only Transformation).

PCA – pagrindinės komponentės analizė (*angl.* principal component analysis)

SOM - Pats besiorganizuojantis požymių žemėlapis (*angl.* Self-organizing map)

MST – minimaliai šakojantis medis (*angl.* minimum spanning tree)

KNN – *K-asis* artimiausias kaimynas (*angl.* K nearest neighbour)

MPM – minimumo ir maksimumo tikimybės mašina (*angl.* minimax probability machine)

LOF – vietinių pašalinių duomenų faktorius (*angl.* local outlier factor)

Įvadas

Kiekvienam gaminiui yra svarbi kokybė. Neskaitant to, kad gaminiai turi turėti kokybišką konstrukciją taip pat svarbu, kad jie ar jų komponentai būtų be defektų. Rankinis defektų tikrinimas gali užimti daug laiko priklausomai nuo objekto. Labai didelė defektų gali būti pastebimi vizualiai. Tai gali būti įtrūkimai, įbrėžimai, tekstūros pasikeitimas ar kita. Tai yra bet kokie nukrypimai nuo nustatytų normų.

Tikrinant gaminių kokybę yra įprasta turėti defektų pavyzdžių, tačiau tiriant paviršius gali būti sudėtinga, ar net neįmanoma susirinkti pakankamai pavyzdžių dėl jų galimos įvairovės. Dėl to tiriamajame darbe naudojami dirbtinio intelekto algoritmai, kuriais apmokomi klasifikatoriai. Klasifikatorių apmokymo medžiaga yra plokštės be defektų. Taip sukuriama kiekvieno pavyzdžio atskira klasė. Klasifikatoriaus testavime panaudojus plokštę su defektu lyginama gautos reikšmės ir pagal bandymų metu nustatytą ribinę reikšmę apsprendžiama ar testuojamas objektas atitinka klasę. Objektai neatitinkantys klasės yra laikomi defektais.

1. Metodų apžvalga

1.1. Dviejų pakopų medienos defektų atpažinimas

Straipsnyje [13] aprašomas metodas skirtas nustatyti parketo kokybę. Šiame metode pirmoje pakopoje algoritmas sudalina vaizdą į mažius stačiakampius ir apskaičiuoja jų spalvų histogramą. Tai laikoma preliminare defektų detekcija. Antroje pakopoje naudojami dirbtinio neuroninio tinklo klasifikatoriai. Jais pilnai atpažįstami defektai.

Pirmoje pakopoje suskirstant į stačiakampius nepersidengčias sritis vaizdas yra analizuojamas tikrinant ar nėra spalvinių nukrypimų nuo bendro vidurkio. Histograma susideda iš visų RGB sistemos spalvų. Procentinės reikšmės skaičiuojamos iš suminės histogramos $C_k(x)$, kuri yra apibrėžta kaip suma normalizuotų histogramų $P_k(x)$, kurios susideda iš nurodyto RGB spalvos kanalo k ir joje esančios reikšmės neviršija reikšmės x . Procentinės ypatybės reikšmės suradimas taip pat yra ir x reikšmės suradimas, kai $C_k(x)$ yra žinomas. Tereikia atlikti $C_k(x)$ inversiją. Pažymėjus procentinę reikšmę kaip $F_k(x)$ funkciją gauname tokį ryšį:


$$F_k(y) = C_k^{-1}(y) = x \quad (1)$$

kur reikšmė y yra suminė histograma [0%; 100%] režiuose.

Pagal perliptą x reikšmę sritys yra suskirstomos į geras ir į įtartinais blogas. Įtartinais blogas dar nėra laikomos visiškai blogomis, nes jos yra papildomai tikrinamos antroje algoritmo pakopoje.

Į defektų atpažinimą yra įtraukiamos visos įtartinos sritys bei dalis gerų, tam, kad klasifikatorius galėtų atskirti ar tarp įtartinų yra visgi ir sričių be defektų.

Neuroninis tinklas tarp įėjimo ir išėjimo naudoja kelių sluoksnių paskirstymą. Tik gretimai esantys sluoksniai gali tiesiogiai vienas kitam perduoti informaciją. Kiekvienas apmokymo pavyzdys yra du kartus paskleidžiamas po tinklą. Kaip įprasta išėjimo sluoksnis duoda rezultatą. Tikrasis išėjimas ir norimas bus su tam tikra paklaida, tačiau atgalinis dauginimas patikslina reikšmių svorius ir slenksčius pasinaudodamas gradientiniu greičiausio nusileidimo metodu, einant nuo išėjimo sluoksnio link įėjimo prieš paklaidos vektorių, ir tai yra kartojama kol pasiekama reikalaujama paklaida. Neuronas laikomas pagrindinius apdorojimo vienetu ir turi kelis įėjimus ir kelis išėjimus (pav. 1.2). Funkcijos f įėjimas yra kiekvieno įėjimo ir jo svorio sandaugos suma, kurie kartu sudaro slenkstinę vertę.



1.2 pav. Dirbtinio neuroninio tinklo neuronas

Apmokant neuroninį tinklą yra svarbu, kad pateikiama mokymosi medžiaga būtų kuo aukštesnės kokybės, tai yra turi būti kuo mažiau vizualinio triukšmo, kuo didesnis kontrastas tarp skirtingų sričių.

Šiuo metodu medienoje yra atpažįstami tokie trūkumai kaip įtrūkimai, skilimai, tuštumos, supuvusios vietos, šakų vietos. Kiekvienas iš defektų vaizde yra matomas skirtingai – tai būna skirtingos formos arba šviesumo dariniai. Pagal defektus parenkami ir neuroninio tinklo įėjimai – tai yra defekto plotas, defekto kraštinės ilgis, defekto vidutinė pilkos spalvos reikšmė, defekto ilgio ir pločio santykis.

Metode naudojamas trijų sluoksnių neuroninis tinklas, kuris susideda iš įėjimų, išėjimų ir paslėpto sluoksnių. Įėjimo sluoksnio neuronų skaičius priklauso nuo įėjimo parametrų, todėl šiuo atveju tai yra 4. Išėjimo sluoksnio neuronai atitinka defektų tipus, todėl turėtų būti 4, bet kadangi norima sistemą supaprastinti, ir kadangi išėjimai iš esmės turi pateikti atsakymą taip arba ne, tai bus iš viso du neuronai skirti išėjimams. Jų reikšmės galės būti 0 arba 1. 1.1 lentelėje pateikta kurios reikšmės atitinka kokį defektą. Dirbtinio neuroninio tinklo išėjimų reikšmės negali būti visiškai tik dviejų reikšmių, todėl jos bus suapvalinamos.

1.1 lentelė. Dirbtinio neuroninio tinklo išėjimų reikšmės

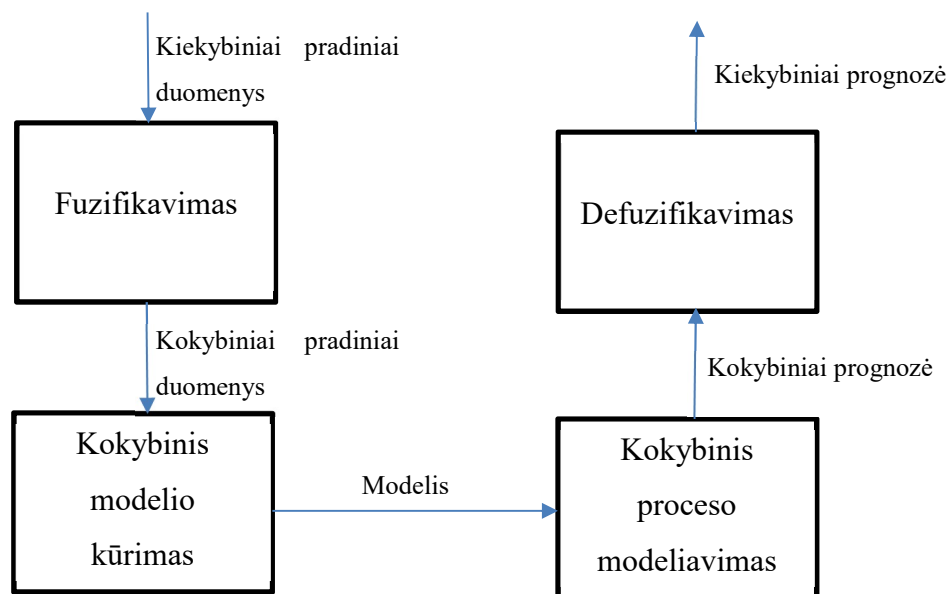
Defektas	Reikšmės
Šaka	0 , 0
Įskilimas	1 , 0
Tuštuma	0 , 1
Pūvimo vieta	1 , 1

Dabartinė teorija negali nurodyti koks yra geriausias kiekis neuronų paslėptame sluoksnyje, todėl dažniausiai tas kiekis nustatomas bandymų metu, taip pat iš sukauptos asmeninės projektuojančio žmogaus patirties. [4] straipsnyje naudojamas toks neuroninis tinklas su kuriuo buvo pasiekti geriausi rezultatai.

1.3. Defektų detekcija naudojantis Fuzzy skirstymą pagal taisykles

Metodas naudojamas tekstilės gaminių kokybės tikrinimui. Tikrinant tekstilę naudojantis vaizdų atpažinimu gaunamas pasikartojantis vaizdas, tuo pačiu beveik visose vietose vienodas. Laikant, kad tikrinama tik medienos kaiščio vaizdas geometrijos viduje, gaunamos panašios sąlygos kaip ir su tekstile. Dėl tekstūros vienodumo pasirinkta analizuoti jos histogramą.

Fuzzy skirstymas pagal taisykles geba sukurti sistemą su įėjimais ir išėjimais. FIR sudaro keturi procesai: fuzifikavimas, kokybinio modelio kūrimas, kokybės modeliavimas, defuzifikavimas. 1.3 pav. pateikta proceso schema.



1.3 pav. proceso schema

Fuzifikavimo proceso metu kiekybinis kintamasis yra kovertuojamas į kokybinį kintamąjį, fuzzy nario kintamąjį ir šoninę reikšmę. Kokybinio modelio kūrimo metu sukuriama vadinamoji kaukė į kurią yra įrašyti klasių ryšiai. Kokybinis modeliavimas numato kaip gali būti atkuriami duomenys, taip pat apjungia senus duomenis su naujo perskaičiavimo. Defuzifikavimas yra atvirkščias procesas sugebantis informaciją atkurti neprarasdamas jos kokybės.

Detekcijos algoritmas prasideda nuo to, kad suskaičiuojamos histogramos atskirai geroms ir negeroms tekstilės vietoms. Toliau atliekamas fuzifikavimas. Pasinaudojus gautais kokybinio modelio kintamaisiais daromos prielaidos koks bus kitos defektuotų vietų histogramos. Pagal tai skaičiuojama paklaida tarp esamų histogramų ir numatomų ir duomenys talpinami į matricą. Gauta matrica filtruojama ir po to tikrinama slenksčio – ar tai tikrai yra defektas.

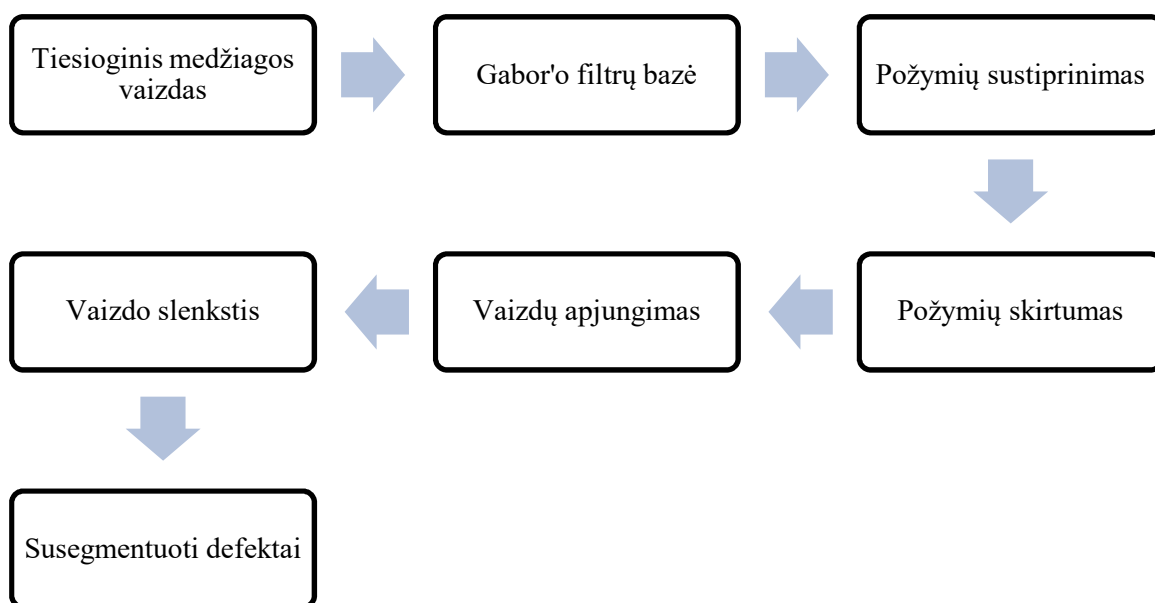
Darbe [15] gauti rezultatai rodo, kad algoritmas veikia tiksliai, aptinka mažus pažeidimus, veikia kai fonas yra su raštu.

1.4. Medžiagų su tekstūros paviršiumi defektų detekcija naudojantis Gaboro filtru

Straipsnyje [16] siūlomas metodas skirtas aptikti tekstūros defektus. Metodas kurtas su tikslu veikti realiu laiku ir naudoti pramonėje tikrinant gaminius. Algoritme pasinaudojus Bernoulli derinimo taisyklėmis apjungiami vaizdai iš skirtingų spalvų kanalų. Metodas tikrinamas naudojantis tekstilės pavyzdžiais iš gamyklos. Fizinis vaizdo dydis ir siūlų netikslumai yra

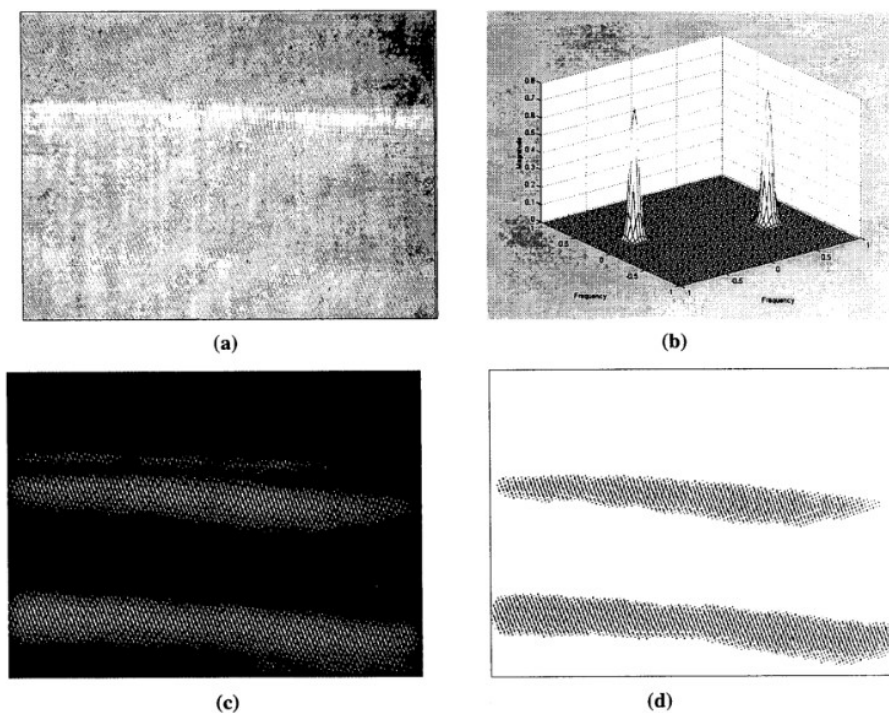
naudojami kaip pagrindiniai parametrai derinant siūlomo algoritmo jautrumą. Pagrindiniai išskirtiniai straipsnio bruožai:

1. Skirtingų informacijos kanalų vaizdai apjungiami pasinaudojus Bernoulli derinimo taisyklėmis. Šis metodas suteikia sparčią detekciją ir mažą klaidų kiekį;
2. Įdiegtas kintamųjų jautrumas, kurio dėka gaunami geresni rezultatai defektuotų siūlų ir didelio fizinio dydžio atžvilgiu.
3. Didelis jautrumas ir maža veikiama vietinė vaizdo sritis algoritmą padaro kompiuterio galios atžvilgiu ekonomišku ir tuo pačiu pagerina realaus laiko veikimo spartą;
4. Taip pat pateikiama defektų detekcija naudojantis stebimais optimaliais Gabor'o filtrais.



1.4 pav. Proceso schema

Gabor'o filtras gali būti naudojamas defektų aptikimui tokiu atveju jeigu yra tinkamai optimizuotas pagal iš anksto žinomą defektą. Pavyzdys pateiktas 1.5 pav. iš darbo [16] kaip naudojantis Gabor filtru gaunamas išryškinas defektas. Vaizdo ypatybės išgaunamos dalinant gauto vaizdo spektrą į keturias skales. Tam, kad būtų filtruojamas visas vaizdas Gabor filtras nustatomas 45° kampo keturiais žingsniais. Iš viso gaunama 16 parinkti taškai kuriems panaudojamos veikimo sritys yra 5×5 arba 7×7 . Gauti 16 vaizdų suformuoja ypatybių vektorių skirtą naudoti defektų detekcijai. Kadangi jau turima objekto be defektų modelis, tai jis yra liginamas su vaizdais kuriuose ieškoma defektų. Defektai gaunami iš vidutinės ir standartinės paklaidos.




1.5 pav. a) medžiagos pavyzdys su defektu, b) Gabor'o filtro duomenys, c) filtruotas vaizdas, d) atskirti defektai

Šio algoritmo kūrėjo rezultatuose pateikiama, kad buvo bandoma su 10 cm ilgio ir 7,5 cm pločio medžiagos plotu ir jo judėjimo greitis buvo 30 cm/s. Jų teigimu gauti rezultatai atitiko kokybės ir spartos lūkesčius. Teigiama, kad metodas gali būti naudojamas įvairioms medžiagoms, kurios turi raštuotą paviršių tikrinti, įskaitant medieną ir plastiką. Tačiau šiame metode tikrinimas tik paviršius, o mano darbe numatoma atlikti bandytus ir su įvairių formų objektais, bet jeigu būtų galima objekto formos turinį, tai yra raštą, atskirti iš vaizdo, tai šis algoritmas galėtų būti naudojamas.

1.5. Plieno paviršiaus defektų detekcija pagrįsta dirbtiniais neuroniniais tinklais ir morfologija

Metodas skirtas atpažinti defektus plieno paviršiuje. Pliene aptinkami defektai yra maži ir įvairių formų. Defektų aptikimui naudojami dirbtiniai neuroniniai tinklai. Norėdami parodyti metodo efektyvumą autoriai gautus rezultatus palygino su paprasčiausiu metodu, kai defektai ir kitokios anomalijos bandomos aptikti naudojantis RGB spalvų kanalų slenksčio vertės viršijimu. Antra, pasinaudojus morfologiniu apdorojimu atfiltruojamas triukšmas. Pasinaudojus tokiais metodais aptinkami skirtingi defektai.

Kaip ir daugelyje kitų metodų tam, kad būtų gauti tikslesni rezultatai pirmiausi atliekamas vaizdo filtravimas su tikslu sumažinti triukšmą. Tai yra įprasta praktika daugelyje darbų ir pritaikomą dažniausiai pagal bandymų sąlygas.




1.6 pav. Neuroninis tinklas

Naudojama neuroninio tinklo struktūra (1.6 pav.) yra beveik identiška į siūlomą [4] darbe – yra įėjimų, paslėptas ir išėjimų sluoksnis. Paslėptame ir išėjimų sluoksniuose naudojama sigmoidinė funkcija 2, kurios išėjimu reikšė yra tarp 0 ir 1:


$$f(x) = 2/(1 + e^{-2x}) \quad (2)$$

Siekiant sumažinti paklaidą kaskart yra perskaičiuojami neuronų sujungimų svoriai. Jų perskaičiavimui naudojami gradientinis greičiausio nusileidimo metodas. Kadangi paslėpti sluoksniai neturi normalaus išėjimo, tai jų sujungimų svoriai perskaičiuojami pasinaudojus paklaidomis išėjimo sluoksniuose.

Neuronų tinklo įėjimų neuronų skaičius yra 3 – kiekvienam RGB kanalui. Vien tik naudojantis neuroniniu tinklu gaunami daug geresnis rezultatai negu tiesiog atskiriant per RGB spalvos slenkstį (1.7 pav). Naudojantis neuroniniu tinklu daug triukšmo yra atmetama kaip netikri defektai, tačiau nors ir geresni rezultatai negu naudojantis RGB slenkščiu, bet jiems pagerinti naudojama antra pakopa – morfologiniu vaizdo apdorojimu [17].



a



b

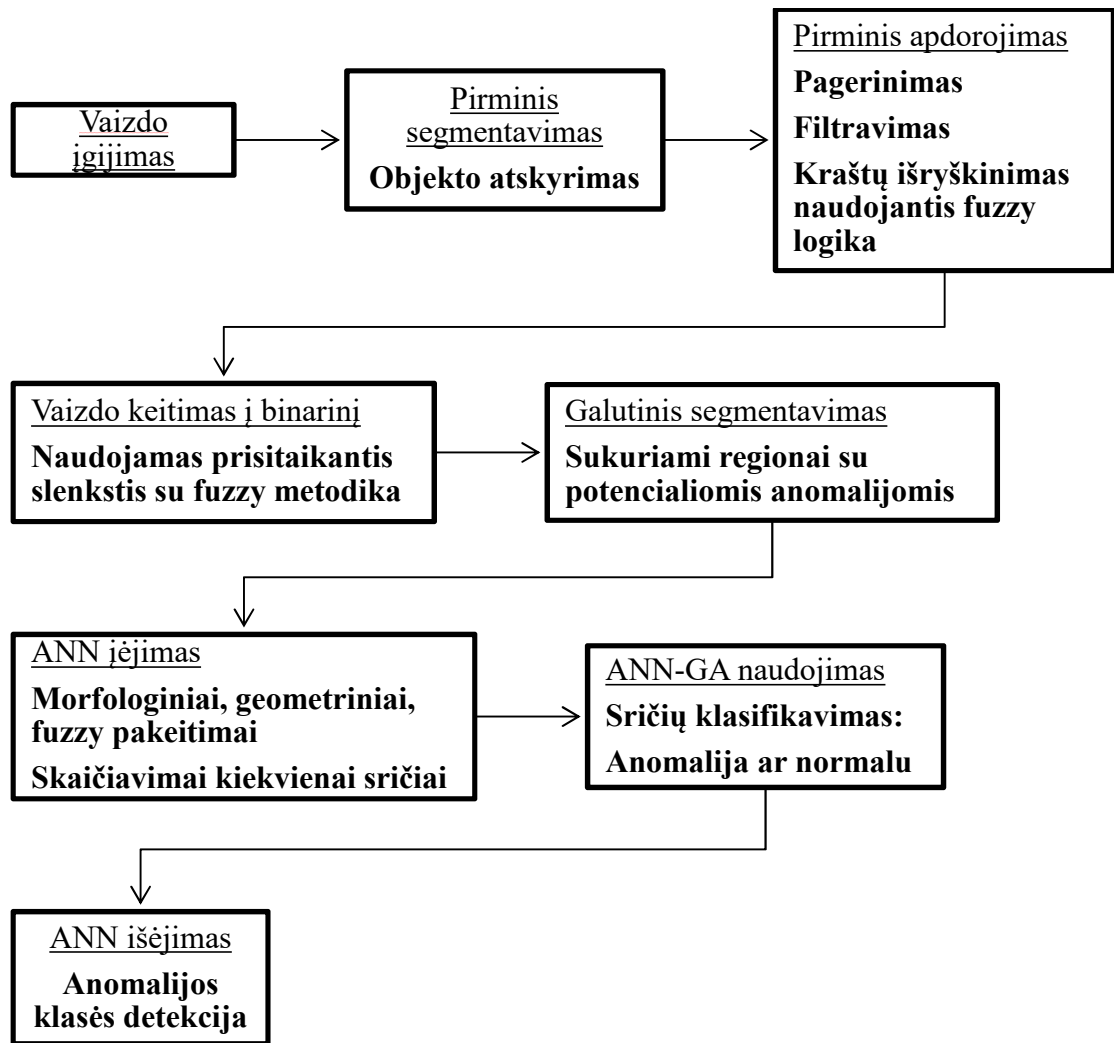
1.7 pav. a - naudotas RGB slenkstis, b - naudoti neuroniniai tinklai

Pirmi naudojami veiksmai atliekant išsiplėtimas ir ardymas – jie naudojami smulkiom detalėm panaikinti, kurios nėra laikomos defektais, o tiesiog yra triukšmo padariniai apdorojant neuroniniais tinklais. Toliau naudojami išplėsti plėtimo ir ardymo metodai – atidarymas ir uždarymas. Jais pasinaudojus panaikinamos vaizde skylės, dvi apjungtos aptikos dėmės atskiriamos į dvi.

Straipsnyje [17] įrodoma, kad palyginus su paprastu RGB atskyrimu verta naudoti neuroninius tinklus, tačiau jame naudoti apdoroti vaizdai yra labai didelio kontrastingumo ir juose sąlyginai paprasčiau aptikti defektus.

1.6. Realus laiko vizualinių anomalijų detekcijos sistemos įdiegimas

Straipsnyje [18] aprašytas sukurtas metodas skirtas aptikti anomalijoms arba defektams veikiant realiu laiku ir esant normalioms apšvietimo sąlygoms. Sukurtas algoritmas naudoja Fuzzy logiką, dirbtinius neuroninius tinklus ir genetinius algoritmus. Sistema priima vaizdą, atskiria reikalingą objektą nuo fono, po to vaizdas yra papildomai apdorojimas naudojantis Fuzzy skirstymo metodais. Tą patį metodą naudoja aptinkant vaizdo vietas su galimais defektais ar anomalijomis ir galiausiai atskiria tikruosius defektus naudojantis mokymosi modeliu pagrįstu dirbtiniais neuroniniais tinklais ir genetiniais algoritmais.



1.8 pav. Algoritmo eigos schema.

Po to, kai fuzzy algoritmas sudaro potencialiai defektuotas sritis, informacija yra perduodama neuroniniui tinklui. Tiksliau yra perduodama srities morfologija, geometrija ir fuzzy gradavimas kiekvienam regionui. Tai ir neuroninio tinklo įėjimai jo apmokymui.

Metodas buvo kuriamas su tikslu aptikti plieninio kabelio defektus. Straipsnio [18] rašymo metu (2003 m.) buvo teigiama, kad sistema gali veikti realiu laiku naudojantis kompiuteriu su Windows operacine sistema arba įterptinės sistemos kompiuteriu. Atsižvelgiant į tai, kad šiandieniniai kompiuteriai yra stipriai pagreitėję galima daryti išvadą, kad šis metodas gali būti ypatingai tinkamas mano atveju. Kaip papildoma informacija apie algoritmo taikymo lankstumą yra pateikta, kad dalis algoritmo yra pritaikyta detektuoti ir sekėti svetimą nuolaužą nuo kylančios daugkartinio naudojimo raketos.

1.7. Neprižiūrima paviršiaus defektų detekcija: dviejų žingsnių metodas

Straipsnyje [19] aprašomas sukurtas algoritmas skirtas aptikti trūkumus gaminio paviršiuje. Metodas veikia dviejomis fazėmis: pirma atliekamas globalus apdorojimas, antra – vietiniai derinimai.

Pirmoje dalyje atliekant globalų apdorojimą pasitelkiama spektrinių sričių būda, kuris panaikina pasikartojančius ir periodinius raštus. Šiame darbe naudojamas Tik Fazės Transformacija (*angl.* Phase Only Transformation – *sutrump.* PHOT)[19]. PHOT dėka panaikinamas vaizdo reguliarumas ir paliekama tik defekto vieta. Tuo pačiu kiekvienas vaizdo taškas įgauna reikšmę atitinkančią jo tikimybę būti defektu. Iš PHOT taip pat gaunama ir slenkstinė reikšmė, pagal kurią toliau taškai suskirstomi kaip galimai priklausantys defekto zonai, ir kaip nepriklausantys. Galiausiai pradiniui vaizdui pritaikomas Gauso filtras. Taip turima du vaizdai – vienas iš jų yra diskretinis galimų defektų žemėlapis, o kitas yra pradinis vaizdas, kai jam yra pritaikytas Gauso filtras.

Antrame žingsnyje defektuotų taškų ieškoma pagal galimų defektų žemėlapi. Tikrinant iš naujo jeigu visi vaizdo taškai srityje $n \times n$ apie tikrinamą tašką atitinka galimų defektų žemėlapi, tai naujame žemėlapyje jis pažymimas kaip defektuotas taškas.

Straipsnio bandymuose defektų buvo ieškoma šlifavimo popieriaus, liejinio, odos, kilimo paviršiuose. Didelis privalumas yra tai, kad defektus atpažįsta ir triukšminguose vaizduose. Tačiau aptiktas defektas pateikiama kaip diskretinė matrica – juoda-balta matrica. Nėra jokio defektų klasifikavimo, galima naudoti tik paviršiams. Tačiau šį metodą būtų galima apjungti su besimokančiais algoritmais, tam, kad būtų galima atskirti defektus pagal jų formą. Taip pat visas arba dalis algoritmo gali būti naudojamas atliekant filtravimą, nes gan optimaliai veikia su įvairiais paviršiais.

1.8. Objekto paviršių anomalijų aptikimas išnaudojant retumą

Siūlomas metodas [20], kuris aptinka anomalijas naudojantis iš vaizdų gautomis, atkuriant vaizdą, liekanomis ir išmoksta koreguoti slenkstinį atskyrimą taip, kad galėtų klasifikuoti vaizdo taškus pagal jų likutinę vertę. Darbe daromos prielaidos, kad anomalijos nėra dažnos (tai yra neužima didžiosios vaizdo dalies) ir, kad anomalijos yra nereikalingos rekonstruojamo vaizdo dalys.

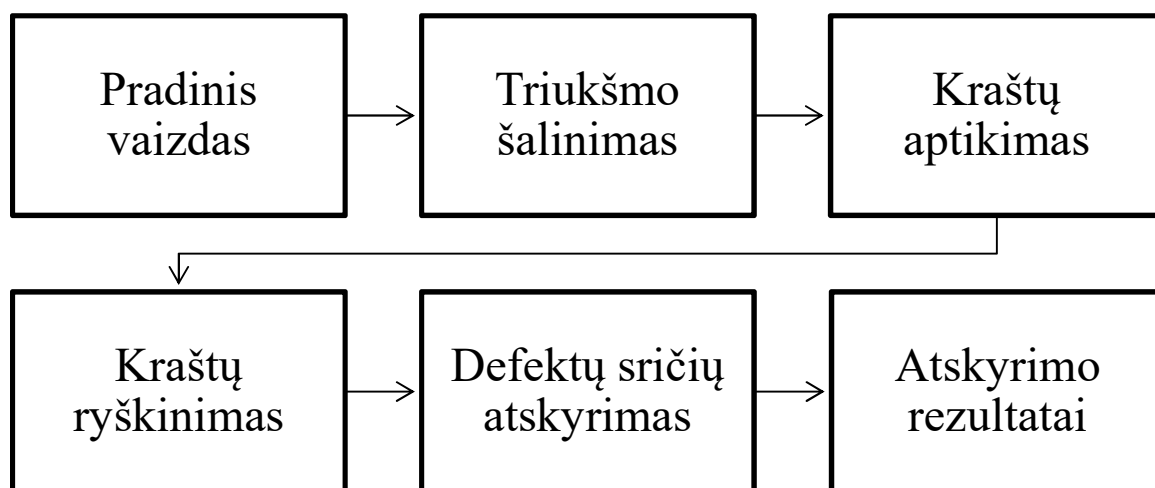
Pirmiausia esamas sumažintas vaizdas lyginamas su duomenų bazėje esančiais tokio pačio gaminio vaizdais be defektų, tolesniams defektų aptikimui pateikiama tik ta sritis kuri išskirtinai daug nesutapo su esančiais duomenų bazėje. Naudojamas stipriai sumažintas vaizdas, nes tada

išvengiama triukšmo ir smulkių atspalvių pakitimų. Toliau pagal vidines nuostatas taškai yra padalinami į diskretinius – kurie tikrai yra defektas ir tie kurie visgi normalūs.

Straipsnyje siūlomas metodas yra neefektyvus dėl didelių kompiuterio naudojamų resursų. Taip pat kokybės patikra gali būti jautri šviesai, taip pat tikrinamas gaminyvisada turi būti vienodai pateikiamas kamerai, nes algoritmas netikrina galimo poslinkio. Atsižvelgiant į visas savybes šio straipsnio metodai nebus naudojami tolesniame darbe.

1.9. Realus laiko algoritmas skirtas aliuminio paviršiaus defektų aptikimui

Straipsnyje [21] aprašomas sukurtas algoritmas, skirtas vaizduose aptikti greitai judančios aliuminio juostos paviršiaus defektus. Pirmiausia naudojami vaizdo apdorojimo metodai panaikinti vaizdo nevienodumą. Toliau vaizde išskiriami defektai. Supaprastinta proceso veikimo schema pateikta 1.9 pav.



1.9 pav. Defektų atskyrimo proceso schema

Vienas iš algoritmo tikslų yra pašalinti vaizdo nevientisumą, kuris gali būti sumaišomas su defektais. Straipsnyje pastebėta, kad naudojant kraštų aptikimą galima panaikinti daug nevientisumo. Naudojamas kryptinis Prewitt operatorius, kuris gali užfiksuoti ne tik krašto orientaciją, bet ir veikia per apdorojimo matricą, kas suteikia spartos. Kraštų aptikimo rezultatai patobulinami entropija pagrįstu slenksčiu. Dėl didesnės spartos naudojama vienmatė entropija (imama vaizdo eilutė). Toliau naudojami morfologiniai metodai šalinant nereikalingą triukšmą, bei tikslinant defektų vaizdus.

Metodas taip pat lyginamas su analogišku metodu (chi-kvadrato detektorius) sparta ir kokybe. Su visais trūkumų tipais geriau veikia siūlomas algoritmas, tačiau 0,3 % daugiau užfiksuojamas

netikras defektas, kai bandoma aptikti skylę. Atsižvelgiant į spartą, tai siūlomo algoritmo vieno kadro apdorojimo trukmė yra 21,4 ms, o chi-kvadrato detektoriaus – 42 ms. Šį algoritmą būtų galima naudoti apjungiant su kitais metodais. Mano atveju jo didžiausios neigiamos pusės yra bendrai paviršiau spalvos ignoravimas ir, kad jį reikėtų sutelkti tik į mažas sritis, kam reikia atskiro algoritmo, tačiau jeigu jis tikslingai veiktų mažose srityse, būtų galima tikėtis pasiekti didelės spartos.

1.10. Paviršiaus defektų detekcija naudojantis perskaičiuojamo slenksčio metodu

Sąlyginai paprastas metodas [22] skirtas aptikti defektus paviršiuje. Naudojamasi perskaičiuojamu slenksčiu. Darbe aprašomi slenksčio perskaičiavimo funkcijos. Pagrindinė slenksčio perskaičiavimo funkcija yra skirta perskaičiuoti praeito ciklo vaizdą suteikiant naują slenkstį. Aprašomi du galimi slenksčiai – kietas ir minkštas. Kietas slenkstis visas reikšmes didesnes ir lygias nei nustatytoji palieka kaip buvo, o visas kitas nustato lygiom 0.

$$H_s(x) = \begin{cases} x_i & \text{jeigu } |x_i| \geq |\xi| \\ 0 & \text{kitaip} \end{cases} \quad (3)$$

Minkštas slenkstis artina reišmes link nulio – siaurina reikšmių diapazoną. Jeigu reikšmė yra didesnė nei nustatytoji, tai ji yra sumažinama, o jeigu mažesnė nei nustatytoji, ji yra prilyginama nuliui.

$$S_\tau(x) = \begin{cases} x - \tau & \text{jeigu } x > \tau \\ 0 & \text{jeigu } |x| \leq \tau \\ x + \tau & \text{jeigu } x < -\tau \end{cases} \quad (4)$$

Metode slenksčio vertė yra paskaičiuojama pagal vyraujančią pilkos spalvos atspalvį, kadangi visi vaizdai iš spalvotų yra verčiami į pilkos spalvos. Gaunamas vaizdas jau būna trijų, o vieno spalvos kanalo, todėl jo apdorojimas tampa spartesnis.

Šį metodą galima laikyti paprasčiausiu, tačiau jis puikiai tinka tada, kai defektai aiškiai išsiskiria savo šviesumu. Kadangi gaunamas diskretinis defekto vaizdas, vėliau galima panaudoti betkokį elementarų diskretinio vaizdo aptikimo algoritmą ir gautą defekto dėmę vaizde pažymėti, priskaičiuoti prie kitų ir t.t.

1.11. Apibendrinimas

Daugelyje metodų bandoma ieškoti nukrypimų nuo statistinių duomenų, tai yra nenaudojamos defektų bibliotekos. Šio tyrimo atveju tai yra naudinga kryptis, nes atsižvelgiant į plokščių tipų ir defektų įvairovę gali būti sudėtinga susidaryti visoms klasėms reikalingus duomenis. Nuspręsta naudoti algoritmus skirtus apibūdinti vaizdų požymius skaliarinėmis reikšmėmis ir duomenis klasifikuoti kaip vieną klasę.

2. Metodika

Tiriamąją dalį sudaro tokie žingsniai:

1. Baldinių plokščių pavyzdžių surinkimas, fotografavimas;
2. Plokščių nuotraukų pirminis apdorojimas;
3. Plokščių raštų požymių pavertimas į skaitines reikšmes;
4. Klasifikatorių apmokymas;
5. Klasifikatorių patikra.

2.1. Duomenų surinkimas


Visam tyrimui buvo parinkta 5 tipų plokščių. Dalis jų turi pasikartojantį raštą, o kita dalis turi tikros miedienos žievės paviršių, kuris kiekviename taške gali skirtis. Priede nr. 1 yra įvairių baldinių plokščių pavyzdžiai.

Visos plokštės buvo nufotografuotos vienodomis sąlygomis. Buvo naudojamas šoninis apšvietimas, šviečiantis iš dviejų šonų. Fotoaparatas buvo nukreiptas statmenai plokštės paviršiaus atžvilgiu. Gautose nuotraukose plokštės 1 mm paviršiaus sudaro 27 taškai. Nuotraukos saugomos CR2 formatu, kiekvienam nuotraukos taškui saugoti naudojama 33 bitai, tai yra kiekvienai spalvai iš RGB paletės skiriama po 11 bitų.

2.2. Pradinis duomenų apdorojimas


Visi tolesni veiksmai buvo atliekami naudojantis „MATLAB“ programiniu paketu. Jis pasirinktas dėl plataus pasirinkimo įrankių ir sąlyginai paprasto programų rašymo.

Paprastai skaitmeninių nuotraukų kiekvieną tašką sudaro trys pagrindinės RGB spalvos, tačiau dirbant su vaizdų apdorojimu daug patogiau yra naudoti HSV sistemą, nes atskiros komponentės yra nevienodai paveikiamos skirtingo apšvietimo skirtingose vaizdo vietose[1]. Pirmas veiksmas apdorojant nuotraukas buvo pakeista spalvų sistema ir atmesta spalvos sodrumo komponentė, taip paliekant tik atspalvio ir šviesumo komponentes (žr. 2.1 pav.).



2.1 pav. Vaizdo dvi komponentės. a – atspalvio, b – šviesumo komponentė.

Kadangi turimos nuotraukos yra sąlyginai didelės raiškos, tai atspalvio ir šviesumo komponentėms buvo panaudotas medianos filtras. Tai leido sumažinti galimą triukšmą bei pašalinti dulkes, kurios nuotraukoje gali užimti kelis taškus.



2.2 pav. a – nuotraukos segmentas prieš filtravimą, b – nuotraukos segmentas po medianos filtro panaudojimo

Kiekvieno tipo baldinės plokštės atspalvio ir šviesumo komponentės išsaugotos viename „MATLAB“ struktūros tipo kintamajame *imageArray*. Toks kintamasis yra išsaugomas atskirame faile su tikslu panaudoti vėliau, nes jo sukūrimas užtrunka kelias minutes.

2.3. Plokščių požymių įvertinimas

Požymių įvertinimui naudojama GLRLM. Kadangi analizuojamos dvi atskiros komponentės, tai jas galima traktuoti kaip pilnkų atspalvių vaizdus. Jį sudaro 11 parametrų gautų vaizdą vertinant 4 kampais: 0° , 45° , 90° ir 135° . Parametrai[2]:

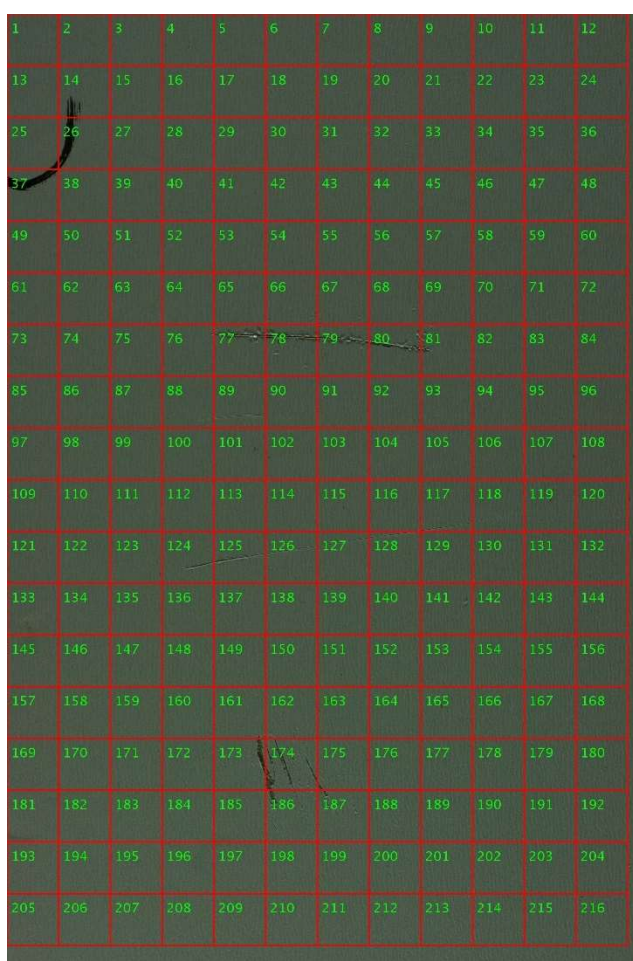
1. SRE – matuoja trumpų išryškėjimų pasiskirstymą. SRE yra stipriai priklausomas nuo trumpų išryškėjimų ir paprastai tolygiose tekstūrose išduoda didelę reikšmę.
2. LRE – matuoja ilgų išryškėjimų pasiskirstymą. LRE yra stipriai priklausomas nuo ilgų išryškėjimų ir paprastai šiurkščiose tekstūrose išduoda didelę reikšmę.
3. GLN – per visą vaizdą matuoja pilkų lygių verčių panašumus. Esant panašioms vaizdo taškų reikšmėms, GLN išduoda mažą reikšmę.
4. RLN – matuoja išryškėjimų ilgių panašumus. Jeigu per visą vaizdą išryškėjimai yra panašaus ilgio, tai RLN reikšmė būna maža.
5. RP – matuoja išryškėjimų homogeniškumą ir pasiskirstymą tam tikra kryptimi. Didžiausia reikšmė gaunama, kai išryškėjimų ilgis tam tikra kryptimi yra artimas 1 visiems pilkos spalvos lygiams (visoms reikšmėms).
6. LGRE – matuoja žemų reikšmių pasiskirstymą. Gaunama didelė reikšmė vaizde esant dažnom žemom reikšmėms.
7. HGRE – matuoja aukštų reikšmių pasiskirstymą. Gaunama didelė reikšmė vaizde esant dažnom aukštom reikšmėms.
8. SRLGE – matuoja jungtinį trumpų išryškėjimų ir žemių pilkų reikšmių pasiskirstymą. Gaunama didelė reikšmė, kai vaizde yra daug trumpų išryškėjimų ir žemių reikšmių.
9. SRHGE – matuoja jungtinį trumpų išryškėjimų ir aukštų pilkų reikšmių pasiskirstymą. Gaunama didelė reikšmė, kai vaizde yra daug trumpų išryškėjimų ir aukštų reikšmių.
10. LRLGE – matuoja jungtinį ilgų išryškėjimų ir žemių pilkų reikšmių pasiskirstymą. Gaunama didelė reikšmė, kai vaizde yra daug ilgų išryškėjimų ir žemių reikšmių.
11. LRHGE - matuoja jungtinį ilgų išryškėjimų ir aukštų pilkų reikšmių pasiskirstymą. Gaunama didelė reikšmė, kai vaizde yra daug ilgų išryškėjimų ir aukštų reikšmių.

Plokščių raštai ir kiti požymiai išreiškiami per pilkų lygių išryškėjimų matricių parametrus. Kadangi nebūtų tikslinga analizuoti viso vaizdo iš karto tai jis yra sudalinamas į kvadratinės formos segmentus, kurio kraštinės ilgis taškais lygus 200 (žr. 2.3 pav.). Visi išgauti parametrai yra saugomi atskiroje matricioje, skirtoje tolesniam naudojimui.

Klasifikatorių apmokymui naudojami GLRLM parametrai, tačiau kadangi kiekvieną parametras sudaro 4 reikšmės atitinkančios vaizdo įvertinimą jį skanuojant iš keturių kampų, tai tolesniam naudojimui imamas 4 reikšmių vidurkis. Kiekvienas klasifikatorius priima dvimačius duomenis, todėl reikia parinkti parametras poras su kuriomis būtų gaunami tiksliausi rezultatai. Klasifikatoriai apmokomi atskirai pagal atspalvio komponentės ir šviesumo komponentės parametrus atskirai. Kadangi naudojamas „dd_tools“ [22] algoritmo rinkinys, tai jam reikia pateikti duomenys specifiniame kintamojo tipe „dataset“ (*liet.* duomenų rinkinys). Paprastai duomenų

rinkinį sudaro tiksliniai duomenys, kurie yra klasifikatoriaus apmokymo pagrindas, ir pašaliniai duomenys, kuriuos klasifikatorius turėtų laikyti kaip nepageidaujamus. Pašaliniai duomenys yra reikalingi norint išgauti gerą klasifikatorių, nes tada geriau atskiriama kas yra klasifikuojamas objektas, ir kas yra visai kitas objektas. Kadangi mano tyrime apmokymui naudojamos tik sveikos plokštės, tai duomenų rinkinyje pateikiami tik tiksliniai duomenys.

Vieną plokštės tipą sudaro 11 parametrų požymiai, ir reikia išbandyti visas porų kombinacijas, tai vienai komponentei gauta 55 kombinacijos, atliekant tai abiejoms komponentėms iš viso apmokymui gaunama 110 kombinacijų. Tai atliekama kiekvienam iš 12 klasifikatorių. Vienos išanalizuotos plokštės visų klasifikatorių duomenys talpinami į vieną matricą, nes jie yra toliau reikalingi testuojant.



1	2	3	4	5	6	7	8	9	10	11	12
13	14	15	16	17	18	19	20	21	22	23	24
25	26	27	28	29	30	31	32	33	34	35	36
37	38	39	40	41	42	43	44	45	46	47	48
49	50	51	52	53	54	55	56	57	58	59	60
61	62	63	64	65	66	67	68	69	70	71	72
73	74	75	76	77	78	79	80	81	82	83	84
85	86	87	88	89	90	91	92	93	94	95	96
97	98	99	100	101	102	103	104	105	106	107	108
109	110	111	112	113	114	115	116	117	118	119	120
121	122	123	124	125	126	127	128	129	130	131	132
133	134	135	136	137	138	139	140	141	142	143	144
145	146	147	148	149	150	151	152	153	154	155	156
157	158	159	160	161	162	163	164	165	166	167	168
169	170	171	172	173	174	175	176	177	178	179	180
181	182	183	184	185	186	187	188	189	190	191	192
193	194	195	196	197	198	199	200	201	202	203	204
205	206	207	208	209	210	211	212	213	214	215	216

2.3 pav. Nuotrauka sudalinta į vienodo dydžio kvadratinus segmentus

2.4. Klasifikatorių apmokymas

Klasifikuojant duomenis į vieną klasę naudojama „MATLAB“ išplėtimai „dd_tools“ ir „pattern recognition toolbox“ (raštų atpažinimo įrankiai). Dėka jų galima susidaryti vienos klasės klasifikatorius. Toliau pateikiami naudojami klasifikavimo metodai.

Autoenkoderis (*angl. autoencoder*)

Skirtas apmokyti autoenkoderio tinklą naudojantis nurodytu kiekiu neuronų, esančių paslėptame sluoksnyje. Tinklas turi išėjime atkurti originalius duomenis. Skirtumas tarp tinklo išėjimo ir originalaus dėsningumo yra panaudojamas kaip klasės aprašymas. Šio matavimo ribinis slenkstis yra optimizuojamas taip, kad apmokymo objektų dalis taškų būtų atmesti.

Autoenkoderiai yra neuroniniai tinklai su paskirtimi būti apmokytais apibendrinti duomenis. Metodas skirtas išėjimo sluoksnyje atkurti įėjimo dėsningumus. Autoenkoderio architektūra sudaro vienas sluoksnis paslėptų neuronų, jų kiekį nurodo .

Tinklas apmokomas atliekant vidutinės kvadratinės paklaidos minimizavimą (naudojant paklaidą iš 5 formulės.

$$f(x) = (x - \text{NeurN}(x))^2 \quad (5)$$

Šios dalies tikslas yra rekonstruoti tikslinį objektą su mažesne paklaida negu pašalinį objektą. Atstumas tarp originalaus objekto ir atkurto ir atstumas iki objekto z yra perduodamas į apmokymo duomenų rinkinį.

$$d_{\text{auto}}(z) = \|f_{\text{auto}}(z; w) - z\|^2 \quad (6)$$

Sprendimas kai autoenkoderyje naudojamas tik vienas sluoksnis yra aprašytas [5]. Tai reiškia, kad autoenkoderio tinklas yra linkęs surasti tokį duomenų aprašą, kuris atitinka PCA aprašymą.

Autoenkoderio tinklas gali turėti didelį kiekį laisvų parametrų. Įėjimo ir išėjimo neuronų kiekis yra nustatomas pagal duomenų dimensijų kiekį d . Pirma yra apibrėžiama autoenkoderio paslėptų elementų kiekis . Formulėje (7) nurodomas bendras svorių kiekis (įskaitant ir paslėptų sluoksnių svorius):

$$n_{\text{freeauto}} = d \times h_{\text{auto}} + h_{\text{auto}} + h_{\text{auto}} \times d + d = (2d + 1)h_{\text{auto}} + d \quad (7)$$

Tai yra svoriai priklausantys tarp įėjimo ir paslėpto sluoksnių, paslėptų sluoksnių svoriai, svoriai tarp paslėptų ir išėjimo sluoksnių ir išėjimo sluoksnių svoriai.

Pritaikyme autoenkoderiai turi tokias pačias problemas kaip ir neuroniniai tinklai [4]. Šis metodas yra labai lankstus, tačiau jam reikalingas iš anksto nustatytas sluoksnių neuronų kiekių reikšmės, taip pat reikalingas kriterijus nurodantis kada pasiekiamos patenkinamos sąlygos, tai yra kada kada galima stabdyti apmokymą. Šio modelio privalumas yra tai, kad jų gautus modelius galima optimizuoti ir iš to yra galimybė gauti labai gerus rezultatus. Nepatyrusiems vartotojams nustatymai gali pasirodyti painūs ir privesti prie silpnų rezultatų.

K-vidurkis (*angl.* K-means)

Duomenų grupavimo metodai gali būti panaudoti kaip paprasčiausio duomenų grupių metodo patobulinimas. Tai padeda tiksliau atvaizduoti duomenų pasiskirstymą. K-vidurkis algoritme turi būti iš anksto nustatyti K grupių centrai. Į algoritmą įtrauktas ir iš naujo atliekamas įvertinimas. Laikykime, kad yra N duomenų taškų x^n ir norime surasti vektorių kiekį K , kur $j = 1, \dots, K$. Algoritmas sprendžia kaip duomenų $\{x^n\}$ taškai galėtų būti padalinti į K atskirų rinkinių S_j turinčių N_j duomenų taškų. Padalinimas vykdomas taip, kad būtų gauta minimizuota kvadratų sumų pagal grupavimo funkciją:

$$J = \sum_{j=1}^K \sum_{n \in S_j} \|x^n - \mu_j\|^2 \quad (8)$$

Kur yra laikomas duomenų taškiu vidurkiu rinkinyje S_j ir yra apskaičiuojamas pagal formulę:

$$\mu_j = \frac{1}{N_j} \sum_{n \in S_j} x^n \quad (9)$$

Bendrai veikianti K-vidurkis ž versija prasideda priskirdama taškus atsitiktiniams K rinkiniams ir tik po to skaičiuoja vidutinius vektorius atitinkančius taškus kiekviename rinkinyje. Toliau kiekvienas taškas yra priskiriamas naujam rinkiniui, priklausomai nuo to kuriam vidutiniui vektoriui jis yra artimesnis. Po šio veiksmo rinkinių vektoriai yra perskaičiuojami. Šie veiksmai kartojami tol, kol nebereikia atlikti daugiau keitimų. Vidutinių reikšmių skaičiavimas gali būti išreikštas ir kaip stochastinis procesas. Šiuo atveju pradiniai centrai yra atsitiktinai parenkami iš duomenų taškų, pateikiamas kiekvienas taškas x^n ir artimiausias yra perskaičiuojamas naudojant:

$$\Delta\mu_j = \eta(x^n - \mu_j) \quad (10)$$

Kur η yra mokymosi spartos parametras. Kai tik bazinės funkcijos centrai yra surast, bazinių funkcijų kovariacinės matricos gali būti nustatytos taškų, priklausančių atitinkamoms grupėms, kovariacijoms [6].

Parzen

Parzen tankumo įvertintojo metodo pagrindai yra sukurti Emanuelio Parzeno ir aprašyti [7]. Šis metodas yra išvestas iš Gauso branduolio sutelkto ties atskirų objektų apmokymu, dažniausiai naudojant kovariacines matricas $\sum_i = h\tau$.

$$p_p(x) = \frac{1}{N} \sum_i p_N(x; x_i, h\tau) \quad (12)$$

Kiekvienos krypties h požymio lygus plotis reiškia, kad Parzen tankumo įvertintojas įvertina, kad požymiai yra vienodo svarbumo ir, kad įvertintojas reaguos į kiekvieno požymio skaliarinį duomenų pasikeitimą, ypač esant mažiems pavyzdžių kiekiams.

Parzen tankumo įvertintojo apmokymas susideda iš vieno parametro apsprendimo - optimalaus h branduolio pločio, todėl:

$$n_{free} = 1 \quad (13)$$

Čia h yra optimizuotas naudojantis maksimalaus panašumo sprendimu [8]. Kadangi įvertinamas tik vienas parametras, tai nėra jokių kitų, kuriuos nustatytų vartotojas. Dėl šios priežasties ir gautas modelis yra labai silpnas. Gaunama, kad modelio aprašas yra visiškai priklausomas nuo apmokymo duomenų rinkinio. Apmokymas nereikalauja didelių kompiuterio skaičiavimo išteklių, bet modelio testavimas palyginus yra reikalaujantis daugiau laiko. Apmokymo metu visi objektai turi būti talpinami modelyje ir atliekant testavimą turi būti suskaičiuojami atstumai iki visų objektų, gauti rezultatai turi būti surūšiuojami pagal dydį. Taip testavimo vieta gali labai apriboti panaudojimą kai yra naudojami dideli apmokymo duomenų rinkiniai, ypač jeigu jie yra sudaryti iš didesnio kiekio dimensijų.

Naïve Parzen

Naïve Parzen metode laikoma, kad regionas yra apibrėžiamas hiperkubu esančiu d -dimensijose ir jo kraštinės ilgis yra h_n . Galime apibrėžti lango funkciją:

$$w(\mathbf{u}) = \begin{cases} 1 & \text{jeigu } \forall j = 1, \dots, d \ |u_j| \leq 1/2 \\ 0 & \text{kitais atvejais} \end{cases} \quad (13)$$

Lango funkcija yra toliau naudojama apsprendžiant \mathbf{x} (paduodamų duomenų) tikimybę.

$$p(\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N \frac{1}{V_N} w\left(\frac{\mathbf{x}-\mathbf{x}_i}{h_N}\right) \quad (14)$$

Šiuo atveju N yra duomenų rinkinių kiekis. Kai rinkinių kiekis artėja prie begalybės, o h_N artėja prie nulio, tai $p(\mathbf{x})$ konverguoja į realią reikšmę.

$$p(\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N \frac{1}{V_N} w\left(\frac{\mathbf{x}-\mathbf{x}_i}{h_N}\right) \xrightarrow{N \rightarrow \infty} \frac{1}{V_N} P\left(x_j - \frac{h_N}{2} < x_j < x_j + \frac{h_N}{2}; \forall j\right) \xrightarrow{h_N \rightarrow 0} p(\mathbf{x}) \quad (15)$$

Minimaliai šakojantis medis (*angl. minimum spanning tree*)

Minimalus išsišakojantis medis yra algoritmas apjungiantis taškus į vieną išsišakojimą. Medžio sudarymui naudojamas Kruskal algoritmas[9]. Pseudo kodas:

Iš visų turimų taškų sudaromos visos galimos kraštinių, tarp kiekvieno taško, kombinacijos;

Kraštinės išrikiuojamos didėjančia tvarka (pagal ilgį)

Kiekvienai išrikiuotai kraštinei e :

jeigu kraštinės galiniai taškai neprijungti prie S

pridėti e prie S

Grąžinti S

Testuojant duomenų tašką gražinamas atstumas iki artimiausios kraštinės.

K-asis artimiausias kaimynas

Algoritmas pradžioje pagal turimus taškus sukuria visus įmanomus atvejus ir klasifikuoja pagal atstumų panašumus. Kiekvienas atvejis klasifikuojamas pagal kaimyninių taškų daugumos balsavimą. Klasifikavimas atliekamas prisikiriant kiekvieną atvejį prie jam artimiausią atstumą turinčios klasės. Atstumo skaičiavimui naudojama Euklido formulė[10]:

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (16)$$

Šis algoritmas nuo paprasto artimiausio kaimyno algoritmo skiriasi tuom, kad atstumas skaičiuojamas iki k artimiausio kaimyno, tai yra ne iki pirmo artimiausio.

Minimumo ir maksimumo tikimybės mašina (*angl. minimax probability machine*)

Algoritmas bando sukurti tiesinį klasifikatorių, kuris atskiria duomenis nuo pradžios, atmetant dalį tikslinių duomenų. Atmetimo slenkstis yra sukuriamas iš tikslinių duomenų[11].

3. Eksperimentai

3.1. Tyrimas


Atrenkant geriausią duomenų rinkinį ir klasifikatorių atlikti bandymai su brokuotų plokščių nuotraukomis. Klasifikatoriaus testavimas vykdomas „MATLAB“ programoje sudauginus duomenų poros rinkinį su klasifikatoriaus matrica. Gaunama reikšmė nusakanti tariamą atstumą nuo turimų duomenų iki klasifikatoriaus apibrėžto objekto. Toks testavimas atliekamas visam vaizdui, jį suskirstant į tokio pačio dydžio zonas kaip ir renkant duomenis apmokymui. Norint įvertinti ar tikrinama zona turi defektų reikalinga ribinė reikšmė. Jeigu gauta srities patikros reikšmė yra mažesnė negu ribinė reikšmė, tai ta sritis pažymima kaip turinti defektą. Ribinė reikšmė kiekvienam plokščių tipui skaičiuojama skirtingai, nes jų parametrų įvertinimas gali būti labai skirtingas. Riba apskaičiuojama imant iš testuotų geros nuotraukų mažiausią gautą reikšmę ir ribą nustatant 10% žemiau mažiausios.

Renkant tiksliausią klasifikatorių naudojama dvejetainė matrica. Matricos dydis atitinka sričių kiekį telpantį į vieną vaizdą ir jos nariai yra nuliai ir vienetai. Vienetas nurodo, kad toje srityje yra defektas (žr. 3.1 pav.).

3.1 lentelė. Klasifikavimo metodų tikslumas

Metodas	Vidutinis klaidų kiekis	Skirtumas nuo geriausio
Autoenc	11,95%	
K vidurkis	12,63%	-0,69%
K-asis artimiausias kaimynas	12,91%	-0,96%
Minimaliai šakojantis medis	12,99%	-1,04%
Ball	13,16%	-1,21%
Vietinių pašalinių duomenų faktoriaus intervale	15,11%	-3,16%
Vietinių pašalinių duomenų faktoriaus	15,11%	-3,17%
Naïve Parzen	15,16%	-3,21%
Minimumo ir maksimumo tikimybės mašina	15,25%	-3,30%
Parzen	16,67%	-4,73%
Atraminiai vektoriai (sv)	17,01%	-5,06%
lp	17,28%	-5,33%


Atliekant klasifikavimo metodų patikrą, gauti klaidų žemėlapiai, kuriuose matomos vietos kuriose dažniausiai klydo visi klasifikatoriai kartu sudėjus. Kiekvienam plokščių tipui gautas klaidų žemėlapis, kurio taškus sudaro visų metodų klaidų suma tuose taškuose (žr. 3.2 pav). Kuo vaizdo vieta baltesnė, tai tuo daugiau tose vietose buvo klaidų.



3.2 pav. Plokščių klaidų matricos. a – balta tekstūra, b – geltona, c – juoda tekstūra, d – mediena tanki, e – tamsi.


Pagal gautus vaizdus padaryta išvada, kad daugiausiai klaidų atlikta ties brokų vietomis, tai reiškia, kad dalis klasifikatorių tiesiog tose vietose neužfiksavo defektų.

Atliktas bandymas keičiant atmetamų duomenų kiekį apmokant. Bandymas atliktas naudojant autoenkoderio metodą ir baltos tekstūros plokščių duomenis (3.3 pav.). Naudojama 4 požymių kombinacija. Skiltis „atmesti“ nurodo kokia dalis duomenų buvo atmesti kaip priešinga grupė, vienetas atitinka visus atmestus duomenis.

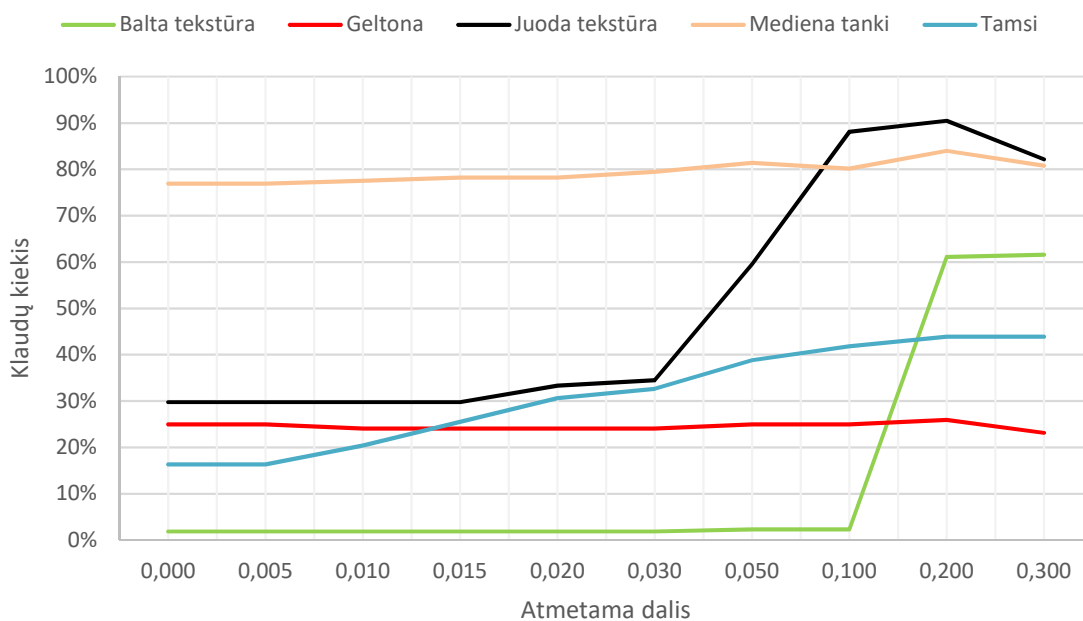


3.3 pav. Klaidų priklausomybė nuo atmetamos dalies

Keičiant atmetamą duomenų dalį metoduose K-vidurkis (3.4 pav.) ir K-asis artimiausias kaimynas (3.5 pav.) nustatyta, kad atmetant vis daugiau duomenų buvo padaroma vis daugiau klaidų išskyrus plokštės „geltona“ atvejį, kurios testavimo metu atmetus 3/10 duomenų gauti geriausi rezultatai.



3.4 pav. K-vidurkio klaidų priklausomybė nuo atmetamos dalies




3.5 pav. K-asis artimiausias kaimynas klaidų priklausomybė nuo atmetamos dalies

Pagal rezultatus gaunama, kad didinant atmetamų duomenų dalį didėja ir klaidų kiekis. Atmetant dešimtadalį duomenų testavimo metu klaidingai sužymima daugiau negu pusė sričių. Geriausias rezultatas gaunamas, kai atmetama 1-1,5% duomenų.

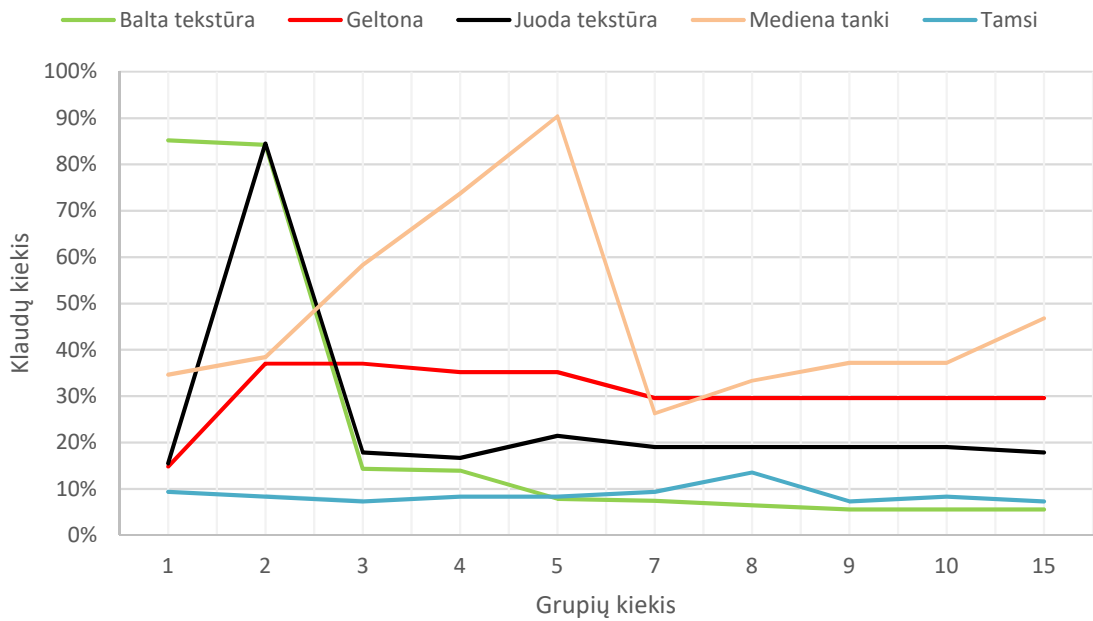
Autoenkoderio tikslumas tikrinamas ir keičiant jo paslėpto sluoksnio neuronų kiekį. Pagal 3.6 pav. grafiką matoma, kad klasifikatorius tikrinant broką mažiausiai klaidų daro turinti 7 – 10

neuronų paslėptame sluoksnyje. Tikrinant plokštę „Balta tekstūra“ neuronų kiekis neturėjo didelės įtakos klaidų skaičiui. Tai gali būti dėl to, kad ši plokštė turi lengviausiai matomą broką, nes jos paviršius yra baltas.



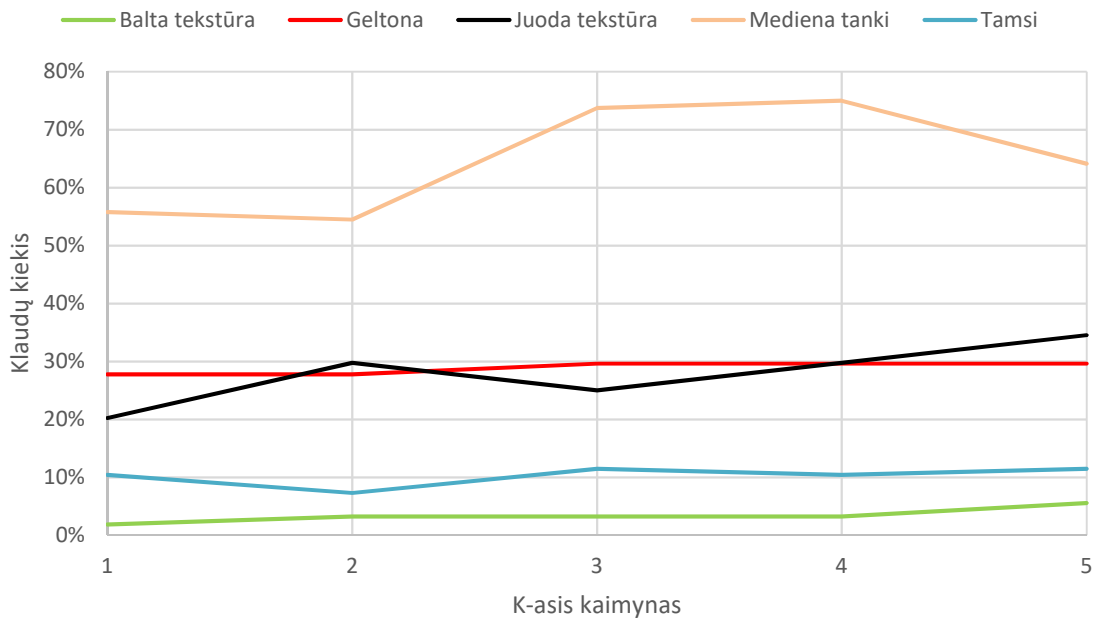
3.6 pav. Klaidų priklausomybė nuo autoenkoderio neuronų kiekio viduriniame sluoksnyje

K-vidurkio metodas tikrintas keičiant jo vidinį parametą – grupių kiekį (3.7 pav. grafikas). Daugeliu atvejų mažiausiai klaidų buvo gaunama, kai naudojamos 7 grupės, tačiau plokštės „geltona“ mažiausias klaidų kiekis gautas, kai buvo naudojama viena grupė. Priede nr. 6 yra atvaizduotas skirtingas duomenų grupavimas, priklausomai nuo nustatyto grupių kiekio, pagal plokštę „geltona“.



3.7 pav. Klaidų priklausomybė nuo K-vidurkio grupių kiekio

Keičiant kelintas yra naudojamas k-asis artimiausias kaimynas gaunama, kad kuo tolimesnis kaimynas yra naudojamas, tuo labiau daugėja klaidų kiekis (3.8 pav. grafikas) Mažiausiai klaidų yra kai naudojamas pirmas arba antras kaimynas. Kadangi keičiant artimiausio kaimyno numerį keičiasi ir klasifikatoriaus apimama sritis, tai į padidėjusias sritis dažniau gali patekti brokas. Priede nr. 7 matoma kaip keičiasi plokštės „geltona“ klasifikatoriaus apimama sritis.



3.8 pav. Klaidų priklausomybė nuo K-asis artimiausias kaimynas nustatyto k-ojo kaimyno

Norint įvertinti defektų detekcijos spartą atlikti laiko matavimai kaip greitai atliekamas vienos srities testavimas su kiekvienu metodu. 3.2 lentelėje matomos testavimo trukmės yra sudarytos iš vieno tipo plokštės testavimų vidurkio. Rezultatai rodo, kad ilgiausiai užtrunka testavimas, kai naudojamas autoenkoderio metodas.

3.2 lentelė. Vidutinė kiekvieno metodo vienos srities testavimo trukmė

Metodas	Trukmė, s
Atraminiai vektoriai (sv)	0,0070
Ball	0,0072
K vidurkis	0,0072
K-asis artimiausias kaimynas	0,0074
Vietinių pašalinių duomenų faktoriaus	0,0085
Minimaliai šakojantis medis	0,0103
Vietinių pašalinių duomenų faktoriaus intervale	0,0106
Minimumo ir maksimumo tikimybės mašina	0,0108
Parzen	0,0121
Naïve Parzen	0,0183
Tiesinio programavimo klasifikatorius	0,0190
Autoenkoderis	0,0197

Atliekant laiko įvertinimą nebuvo svarbus plokštės tipo parinkimas, nes tai santykinis vertinimas lyginant metodus tarpusavyje. Taip pat dėl, kad parinkus įvairių tipų plokštes gaunama sąlyginai panaši testavimo trukmė (3.3 lentelė).

3.3 lentelė. Vidutinė testavimo trukmė naudojant skirtingų tipų plokštes

Plokštės tipas	Testavimo trukmė, s
Balta tekstūra	0,0197
Geltona	0,0210
Juoda tekstūra	0,0206
Mediena tanki	0,0188
Tamsi	0,0186

Išvados

1. Mažiausiai klaidų darantis klasifikavimo metodas yra autoenkoderis. Vidutiniškai su visų penktių tipų plokštėmis autoenkoderio klasifikatorius klusta 11,95%.
2. Matuojant segmento testavimo trukmę nustatyta, kad autoenkoderio klasifikatoriaus testavimas užtrunka ilgiausiai, tai yra vidutiniškai 0,0197 s. Tačiau K-vidurkis ir K-asis artimiausias kaimynas metodai yra atitinkamai antras (0,0072 s) ir trečias (0,0074s) greičiausiai veikiančys metodai, todėl atsižvelgiant į praktinį pritaikymą jie būtų sąlyginai spartus ir kokybiškas pasirinkimas. Jie taip pat yra atitinkamai antras (12,63%) ir trečias (12,91%) mažiausiai darantys klaidų.
3. Su daugeliu plokščių mažinant atmetamų duomenų kiekį gaunamas vis mažiau klaidų darantis klasifikatorius. Išskyrus naudojant autoenkoderio klasifikatorių, kurio atveju klaidų kiekis varijuoja visame testuotame intervale.
4. Daugiausiai klaidų gauta testuojant plokštę „mediena tanki“. Daugelyje bandymų virš 50% jos segmentų buvo klaidingai pažymimi kaip gera vieta arba brokas. Tai gali būti dėl jos sudėtingo rašto, kuriame įbrėžimai ir kitoks brokas nedaug skiriasi nuo pačio paviršiaus
5. Testuojant plokštę „geltona“ daugelyje bandymų gauta, kad panašus kiekis klaidų.
6. Nėra vienos idealios rašto požymių parametrų kombinacijos tinkančios klasifikatorių apmokymui. Tinkamiausio požymių parametrų parinkimas priklauso nuo to kokie yra rašto ryškiausi požymiai. Norint tokius požymius panaudoti praktikoje reikėtų jų atskiras kombinacijas nustatyti pagal testuojamas plokštes.
7. Klasifikuojant šviesių plokščių duomenis geriausi rezultatai gaunami, kai analizuojama atspalvio komponentė. Klasifikuojant tamsias plokštes geriausi rezultatai gaunami analizuojant šviesumo komponentę. Taip yra todėl, nes šviesesnėse plokštėse atspalvio komponentės duomenys turi mažiau triukšmo. Testuojant plokštę „balta tekstūra“ geriausius rezultatus naudojant atspalvio komponentę suteikė 11 iš 12 metodų. Naudojant plokštes „geltona“ ir „mediena tanki“ su visais metodais mažiausiai klaidų gauta naudojant atspalvio komponentę.
8. Klasifikuojant idealus kiekis duomenų laikomų kaip ne tikslinės grupės yra apie 1-1,5%. Didinant ne tikslinės grupės duomenų kiekį stipriai didėja klaidų kiekis.

Literatūros sąrašas

- [1] Gautam Kumar, P. Parth Sarthi, Prabhat Ranjan, R. Rajesh. „Performance of k-means based satellite image clustering in RGB and HSV color space“. 2016 International Conference on Recent Trends in Information Technology (ICRTIT). 2016. (Prieiga internete <http://ieeexplore.ieee.org/document/7569523/>)
- [2] Dong-Hui Xu, Arati S. Kurani, Jacob D. Furst, Daniela S. Raicu. „Run-Length Encoding For Volumetric Texture“. Intelligent Multimedia Processing Laboratory, School of Computer Science, Telecommunications, and Information Systems, DePaul University, Chicago, Illinois, 60604, USA. (Prieiga internete http://facweb.cs.depaul.edu/research/vc/publications/final_submission_paper_452_1_31_last.pdf)
- [3] door David Martinus Johannes. Proefschrift „One-class classification Concept-learning in the absence of counter-examples“. 2001
- [4] Nathalie Japkowicz, Catherine Myers, Mar k Gluck. „A Novelty Detection Approach to Classification“. Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence, puslapiai 518–523. (Prieiga internete <http://www.ijcai.org/Proceedings/95-1/Papers/068.pdf>)
- [5] H. Boullard, Y. Kamp. „Auto-Association by Multilayer Perceptrons and Singular Value Decomposition“. Biological Cybernetics, 59:291–294. (Prieiga internete <http://ace.cs.ohio.edu/~razvan/courses/dl6890/papers/boullard-kamp88.pdf>)
- [6] Christopher M. Bishop. „Neural Networks for Pattern Recognition“. Department of Computer Science and Applied Mathematics Aston University Birmingham, UK. 1995. psl. 187 – 188. (Prieiga internete http://cs.du.edu/~mitchell/mario_books/Neural_Networks_for_Pattern_Recognition_-_Christopher_Bishop.pdf)
- [7] E. Parzen. „On the estimation of a probability density function and the mode“. Annals of Math. Stats., 33:1065-1076, 1962. (Prieiga internete <http://bayes.wustl.edu/Manual/parzen62.pdf>)
- [8] Kraaijveld, M. and Duin, R. „A criterion for the smoothing parameter for parzen-estimators of probability density functions. Technical report“, Delft University of Technology. 1991.
- [9] ICS 161: Design and Analysis of Algorithms Lecture notes for February 6, 1996. (Prieiga internete <https://www.ics.uci.edu/~eppstein/161/960206.html#kruskal>)

- [10] K Nearest Neighbors – Classification. (Prieiga internete http://www.saedsayad.com/k_nearest_neighbors.htm)
- [11] Gert R.G. Lanckriet, Laurent El Ghaoui, Michael I. Jordan. „Robust Novelty Detection with Single-Class MPM“. S. Becker, S. Thrun, and K. Obermayer, editors, Advances in Neural Information Processing Systems, volume 15. MIT Press: Cambridge, MA, 2003. (Prieiga internete <https://papers.nips.cc/paper/2187-robust-novelty-detection-with-single-class-mpm.pdf>)
- [12] A two stage defect recognition method for parquet slab grading, Hannu Kauppinen, University of Oulu, 2000; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=903039>)
- [13] Research on recognition of wood defect types based on back-propagation neural network, D. Qi, P. Zhang, L. Yu, X. Zhang, College of Science, China, 2008; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=4597794>)
- [14] Fabric Defect Detection Using Fuzzy Inductive Reasoning Based on Image Histogram Statistic Variables, Yuan Ye, Beijing Institute of Fashion Technology, 2009; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=5359825>)
- [15] Defect detection in textured materials using Gabor filters, A. Kumar, Hong Kong University, 2000; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=881960>)
- [16] Recognition of Defects in Steel Surface Image Based on Neural Networks and Morphology, C. Yang, J. Zhang, G. Ji, Y. Fu, X. Hong; Chongqing Institute of technology, 2007; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=4414530>)
- [17] Implementation of a general real-time visual anomaly detection system via soft computing, 2003, Jesus A. Dominguez; ASRC Aerospace corporation; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?reload=true&arnumber=1206576>)
- [18] Unsupervised detection of surface defects: A two-step approach, J. Choi, C. Kim; Korea Advanced Institute of Science and Technology, 2012; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6467040>)
- [19] Exploiting sparsity for image-based object surface anomaly detection, W. H. Chai, S. Ho, C. Goh, Rolls-Royce @ Nanyang Technological University Corporate Lab, 2016; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=7844444>)

http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=7472024&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D7472024)

- [20] A real-time algorithm for aluminum surface defect extraction on non-uniform image from CCD camera, X. Huang, X. Luo; Suzhou Non-ferrous metals research institute; 2014; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=7009668>)
- [21] Metal surface defect detection using iterative thresholding technique, M. Senthikumar, Dr. V. Palanisamy, Dr. J. Jaya; Anna University; 2014; (Prieiga internete <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6966360>)
- [22] dd_tools algoritmu rinkinys (Prieiga internete http://prlab.tudelft.nl/david-tax/dd_tools.html)

Priedai

Nr. 1


Baldinių plokščių naudotų tyrime tipai

Nuotrauka


Pavadinimas, kuris buvo
naudojamas tyrime




Balta tekstūra



Geltona



Juoda tekstūra



Mediena tanki



Tamsi

Nr. 2

Kombinacijų numerių ir rašto požymių porų lentelė

Kombinacijos nr.	Požymių parametrų numerių poros	Kombinacijos nr.	Požymių parametrų numerių poros
1	2 ir 1	29	6 ir 4
2	3 ir 1	30	7 ir 4
3	4 ir 1	31	8 ir 4
4	5 ir 1	32	9 ir 4
5	6 ir 1	33	10 ir 4
6	7 ir 1	34	11 ir 4
7	8 ir 1	35	6 ir 5
8	9 ir 1	36	7 ir 5
9	10 ir 1	37	8 ir 5
10	11 ir 1	38	9 ir 5
11	3 ir 2	39	10 ir 5
12	4 ir 2	40	11 ir 5
13	5 ir 2	41	7 ir 6
14	6 ir 2	42	8 ir 6
15	7 ir 2	43	9 ir 6
16	8 ir 2	44	10 ir 6
17	9 ir 2	45	11 ir 6
18	10 ir 2	46	8 ir 7
19	11 ir 2	47	9 ir 7
20	4 ir 3	48	10 ir 7
21	5 ir 3	49	11 ir 7
22	6 ir 3	50	9 ir 8

23	7 ir 3		51	10 ir 8
24	8 ir 3		52	11 ir 8
25	9 ir 3		53	10 ir 9
26	10 ir 3		54	11 ir 9
27	11 ir 3		55	11 ir 10
28	5 ir 4			

Nr. 3

Rašto požymių parametrai

Parametro numeris	Parametro trumpinys (žr. 3.3 skyių)
1	SRE
2	LRE
3	GLN
4	RLN
5	RP
6	LGRE
7	HGRE
8	SRLGE
9	SRHGE
10	LRLGE
11	LRHGE

balta tekstūra	autoenc		ball		kmeans		knn		lof		lofrange		lpdd		mpm		mst		nparzen		parzen		sv	
	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi
3.70%	4	5.09%	1	4.63%	4	4.17%	4	5.09%	7	6.02%	7	5.09%	7	6.02%	11	4.17%	4	4.17%	16	7.41%	16	7.41%	61	5.09%
3.70%	6	5.09%	2	4.63%	5	4.63%	13	6.02%	1	6.02%	1	6.02%	1	6.02%	18	6.02%	13	4.17%	6	4.63%	1	7.41%	70	6.48%
3.70%	13	5.09%	3	4.63%	7	5.09%	7	6.02%	13	6.02%	13	6.48%	13	6.48%	18	6.02%	18	4.17%	8	4.63%	2	7.41%	91	6.48%
4.17%	8	5.09%	4	5.09%	18	5.09%	44	6.02%	14	6.02%	14	6.94%	14	6.94%	1	4.17%	9	4.63%	3	7.41%	3	7.41%	96	6.48%
4.17%	18	5.09%	5	5.09%	35	6.02%	1	6.02%	16	6.02%	16	6.94%	14	6.94%	14	4.17%	10	4.63%	4	7.41%	4	7.41%	101	6.48%
4.17%	19	5.09%	6	6.02%	13	6.02%	16	6.48%	18	6.48%	18	6.94%	16	6.94%	16	4.17%	15	4.63%	5	7.41%	5	7.41%	102	6.48%
4.17%	39	5.09%	8	6.48%	37	6.94%	11	8.33%	75	7.41%	35	7.87%	5	7.41%	20	4.17%	17	4.63%	6	7.41%	6	7.41%	103	6.94%
4.63%	5	5.09%	9	6.94%	1	6.94%	33	8.80%	56	8.33%	62	8.80%	42	7.87%	2	4.17%	18	4.63%	7	8.33%	7	8.33%	104	9.26%
4.63%	9	5.09%	10	6.94%	14	7.41%	5	8.80%	62	8.80%	62	8.80%	56	9.26%	3	4.17%	19	4.63%	8	8.33%	8	8.33%	109	9.26%
4.63%	14	5.56%	7	6.94%	16	7.41%	20	8.80%	68	8.80%	68	8.80%	68	9.26%	3	7.87%	12	4.17%	47	4.63%	9	8.80%	63	9.26%
4.63%	42	5.56%	16	7.41%	16	7.41%	26	8.80%	69	8.80%	69	9.26%	69	9.26%	4	7.87%	21	4.63%	5	4.63%	10	8.80%	65	9.26%
4.63%	44	5.56%	24	7.87%	20	7.41%	35	8.80%	71	8.80%	71	9.26%	71	9.26%	6	7.87%	22	4.63%	7	4.63%	24	8.80%	72	9.26%
5.09%	10	5.56%	31	7.87%	39	7.41%	37	9.26%	2	9.26%	2	9.26%	2	9.26%	8	7.87%	24	4.63%	12	4.63%	31	8.80%	74	9.26%
5.09%	12	5.56%	37	8.33%	3	7.41%	42	9.26%	3	9.26%	3	9.26%	3	9.26%	9	7.87%	26	4.63%	13	4.63%	37	8.80%	82	9.26%
5.09%	17	5.56%	42	8.33%	9	7.87%	2	9.26%	4	9.26%	4	9.26%	4	9.26%	28	4.63%	28	4.63%	39	5.09%	14	8.80%	89	9.26%
5.09%	33	5.56%	46	8.33%	12	7.87%	3	9.26%	5	9.26%	5	9.26%	5	9.26%	11	7.87%	29	4.63%	44	5.09%	42	8.80%	93	9.26%
5.56%	35	5.56%	50	8.33%	28	7.87%	6	9.26%	6	9.26%	6	9.26%	6	9.26%	12	7.87%	31	4.63%	54	5.09%	46	8.80%	95	9.26%
5.56%	50	5.56%	51	8.33%	29	7.87%	8	9.26%	8	9.26%	8	9.26%	8	9.26%	15	7.87%	33	6.02%	50	5.09%	50	8.80%	98	9.26%
6.02%	7	5.56%	52	8.33%	31	7.87%	10	9.26%	9	9.26%	9	9.26%	9	9.26%	17	8.80%	39	6.02%	11	5.09%	52	8.80%	100	9.26%
6.02%	16	7.41%	13	8.33%	33	7.87%	12	9.26%	10	9.26%	10	9.26%	10	9.26%	19	9.26%	4	6.02%	14	5.56%	12	8.80%	105	9.26%


geltona	autoenc		ball		kmeans		knn		lof		lofrange		lpdd		mpm		mst		nparzen		parzen		sv	
	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi	klaids	kombi
4.63%	6	6.48%	13	6.48%	13	6.48%	4	5.56%	6	6.48%	6	5.56%	6	6.48%	4	7.41%	1	6.48%	4	7.41%	5	7.41%	5	6.48%
4.63%	15	6.48%	21	6.48%	21	6.48%	6	5.56%	8	6.48%	8	5.56%	8	6.48%	35	7.41%	13	6.48%	6	7.41%	7	7.41%	7	6.48%
4.63%	23	6.48%	28	6.48%	28	6.48%	8	5.56%	10	6.48%	10	5.56%	10	6.48%	37	7.41%	14	6.48%	8	19.44%	16	22.22%	64	6.48%
4.63%	34	6.48%	35	6.48%	35	6.48%	10	5.56%	15	6.48%	15	5.56%	15	6.48%	17	7.41%	16	6.48%	10	19.44%	37	22.22%	99	7.41%
4.63%	38	6.48%	36	6.48%	36	6.48%	15	5.56%	17	6.48%	17	5.56%	17	7.41%	5	7.41%	18	6.48%	15	19.44%	42	22.22%	106	7.41%
4.63%	40	6.48%	37	6.48%	37	6.48%	17	5.56%	19	7.41%	19	7.41%	19	7.41%	7	10.19%	3	6.48%	17	19.44%	46	25.00%	1	7.41%
4.63%	41	6.48%	38	6.48%	38	6.48%	19	5.56%	23	6.48%	23	5.56%	23	7.41%	13	10.19%	12	6.48%	19	19.44%	50	25.00%	2	7.41%
4.63%	46	6.48%	39	6.48%	39	6.48%	23	5.56%	25	6.48%	25	5.56%	25	7.41%	14	10.19%	28	6.48%	23	19.44%	52	25.00%	3	7.41%
4.63%	49	6.48%	40	6.48%	40	6.48%	25	5.56%	27	6.48%	27	5.56%	27	7.41%	16	10.19%	29	6.48%	25	20.37%	51	25.00%	4	7.41%
4.63%	52	6.48%	47	6.48%	47	6.48%	27	5.56%	30	6.48%	30	5.56%	30	7.41%	18	10.19%	31	6.48%	27	21.30%	31	25.00%	6	7.41%
4.63%	54	6.48%	49	6.48%	49	6.48%	30	5.56%	32	6.48%	32	5.56%	32	19.44%	42	10.19%	33	6.48%	30	22.22%	81	25.00%	8	19.44%
4.63%	55	6.48%	54	6.48%	54	6.48%	32	5.56%	34	6.48%	34	5.56%	34	20.37%	9	11.11%	2	6.48%	32	22.22%	103	25.00%	9	20.37%
5.56%	8	7.41%	1	6.48%	34	5.56%	34	5.56%	36	6.48%	35	5.56%	36	20.37%	39	11.11%	11	6.48%	34	22.22%	108	25.00%	10	20.37%
5.56%	10	7.41%	2	6.48%	35	5.56%	35	5.56%	38	6.48%	36	5.56%	38	20.37%	44	11.11%	21	6.48%	35	22.22%	110	25.00%	11	20.37%
5.56%	27	7.41%	3	6.48%	36	5.56%	36	5.56%	40	6.48%	37	5.56%	40	20.37%	51	11.11%	22	6.48%	36	23.15%	24	25.00%	12	20.37%
5.56%	43	7.41%	4	6.48%	37	5.56%	37	5.56%	41	6.48%	38	5.56%	41	22.22%	62	11.11%	24	6.48%	37	23.15%	94	25.00%	13	22.22%
5.56%	45	7.41%	5	6.48%	38	5.56%	38	5.56%	43	6.48%	40	5.56%	43	24.07%	64	11.11%	26	6.48%	38	25.00%	1	25.00%	14	22.22%
5.56%	47	7.41%	6	6.48%	40	5.56%	40	5.56%	45	6.48%	41	5.56%	45	24.07%	99	22.22%	9	6.48%	40	25.00%	2	25.00%	15	22.22%
5.56%	50	7.41%	8	6.48%	41	5.56%	41	5.56%	46	6.48%	43	5.56%	46	24.07%	106	22.22%	39	6.48%	41	25.00%	3	25.00%	16	22.22%
6.48%	4	7.41%	9	6.48%	43	5.56%	43	5.56%	47	6.48%	45	5.56%	47	25.00%	2	22.22%	44	6.48%	43	25.00%	4	25.00%	17	25.00%

juoda tekstūra autoenc		ball		kmeans		knn		lof		lofrange		lodd		mpm		mst		nparzen		parzen		sv	
klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi
20,24%	75	22,62%	73	22,62%	64	19,05%	73	17,86%	89	22,62%	64	23,81%	97	19,05%	73	19,05%	73	22,62%	73	19,05%	73	21,43%	73
21,43%	73	22,62%	81	22,62%	73	22,62%	64	23,81%	56	22,62%	99	25,00%	1	22,62%	64	22,62%	64	22,62%	64	22,62%	88	22,62%	64
22,62%	64	22,62%	88	22,62%	99	22,62%	99	23,81%	64	22,62%	106	25,00%	2	22,62%	99	22,62%	99	22,62%	99	22,62%	99	22,62%	99
22,62%	72	22,62%	103	22,62%	106	22,62%	106	23,81%	68	23,81%	56	25,00%	3	22,62%	106	22,62%	106	22,62%	106	22,62%	103	23,81%	106
22,62%	99	22,62%	108	23,81%	56	23,81%	56	23,81%	94	23,81%	57	25,00%	4	23,81%	56	23,81%	56	22,62%	56	22,62%	106	23,81%	94
22,62%	103	22,62%	110	23,81%	69	23,81%	57	23,81%	97	23,81%	66	25,00%	5	23,81%	69	23,81%	69	22,62%	69	22,62%	108	23,81%	97
22,62%	106	23,81%	67	23,81%	94	23,81%	69	25,00%	2	23,81%	71	25,00%	6	23,81%	71	23,81%	71	22,62%	71	22,62%	110	23,81%	1
22,62%	110	23,81%	67	23,81%	94	23,81%	69	25,00%	2	23,81%	71	25,00%	7	23,81%	94	23,81%	94	23,81%	75	23,81%	66	23,81%	2
23,81%	57	23,81%	69	23,81%	97	23,81%	71	25,00%	3	23,81%	73	25,00%	8	25,00%	1	23,81%	87	23,81%	87	23,81%	67	23,81%	3
23,81%	66	23,81%	70	25,00%	1	23,81%	75	25,00%	4	23,81%	76	25,00%	9	25,00%	2	23,81%	94	23,81%	94	23,81%	69	23,81%	4
23,81%	68	23,81%	72	25,00%	2	23,81%	76	25,00%	5	23,81%	77	25,00%	10	25,00%	3	23,81%	97	23,81%	97	23,81%	70	23,81%	5
23,81%	70	23,81%	74	25,00%	3	23,81%	77	25,00%	6	23,81%	78	25,00%	11	25,00%	4	25,00%	1	23,81%	72	25,00%	72	25,00%	6
23,81%	74	23,81%	77	25,00%	4	23,81%	78	25,00%	7	23,81%	79	25,00%	12	25,00%	5	25,00%	2	23,81%	74	25,00%	74	25,00%	7
23,81%	76	23,81%	84	25,00%	5	23,81%	79	25,00%	8	23,81%	80	25,00%	13	25,00%	6	25,00%	3	23,81%	84	25,00%	84	25,00%	8
23,81%	77	23,81%	80	25,00%	6	23,81%	80	25,00%	9	23,81%	81	25,00%	14	25,00%	7	25,00%	4	23,81%	90	25,00%	90	25,00%	9
23,81%	79	23,81%	94	25,00%	7	23,81%	81	25,00%	10	23,81%	82	25,00%	15	25,00%	8	25,00%	5	23,81%	94	25,00%	94	25,00%	10
23,81%	81	23,81%	96	25,00%	8	23,81%	85	25,00%	11	23,81%	89	25,00%	16	25,00%	9	25,00%	6	23,81%	96	25,00%	96	25,00%	11
23,81%	82	23,81%	98	25,00%	9	23,81%	87	25,00%	12	23,81%	94	25,00%	17	25,00%	10	25,00%	7	23,81%	98	25,00%	98	25,00%	12
23,81%	94	23,81%	99	25,00%	10	23,81%	94	25,00%	13	23,81%	97	25,00%	18	25,00%	11	25,00%	8	23,81%	100	25,00%	100	25,00%	13
23,81%	97	23,81%	100	25,00%	11	23,81%	97	25,00%	14	25,00%	1	25,00%	19	25,00%	12	25,00%	9	25,00%	1	25,00%	1	25,00%	14

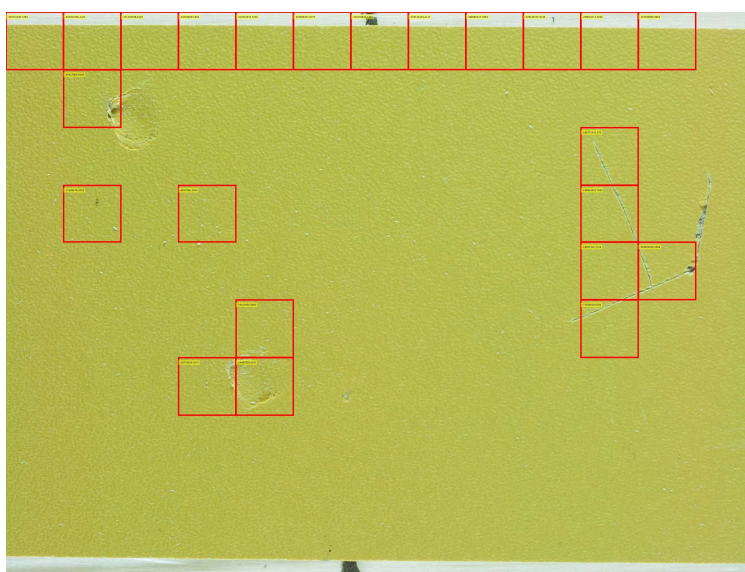
mediena tanki		ball		kmeans		knn		lof		lofrange		lodd		mpm		mst		nparzen		parzen		sv	
autoenc	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi
3,21%	39	7,69%	13	6,41%	35	5,77%	35	13,46%	5	6,41%	35	14,74%	4	7,69%	4	7,05%	3	5,13%	35	5,77%	28	5,77%	35
5,13%	53	7,69%	21	7,05%	6	8,33%	3	16,67%	39	12,18%	39	14,74%	37	7,69%	37	8,97%	12	8,97%	39	9,62%	3	14,74%	37
6,41%	25	7,69%	28	7,05%	8	8,33%	12	17,31%	2	15,38%	5	15,38%	35	7,69%	35	8,97%	28	8,97%	47	6,41%	36	9,62%	12
6,41%	47	7,69%	36	7,05%	10	8,33%	28	17,31%	11	20,51%	9	17,31%	1	7,69%	1	7,69%	29	8,97%	49	6,41%	38	9,62%	28
6,41%	49	7,69%	38	7,05%	15	8,33%	29	17,31%	14	21,15%	14	17,31%	7	7,69%	7	8,97%	31	8,97%	54	6,41%	40	9,62%	29
6,41%	54	7,69%	39	7,05%	17	8,33%	31	17,31%	16	21,15%	16	17,31%	13	7,69%	13	10,90%	33	10,90%	25	6,41%	47	9,62%	31
7,05%	20	7,69%	40	7,05%	19	8,33%	33	17,31%	18	21,79%	1	17,31%	14	12,82%	20	11,54%	23	6,41%	23	6,41%	49	9,62%	33
7,05%	52	9,62%	47	7,05%	23	10,26%	37	17,31%	21	21,79%	2	17,31%	16	16,03%	2	11,54%	27	6,41%	27	6,41%	54	10,26%	37
8,97%	38	9,62%	49	7,05%	25	10,90%	4	17,31%	22	21,79%	3	17,31%	18	16,03%	11	11,54%	41	8,33%	30	10,90%	4	17,31%	18
9,62%	31	9,62%	54	7,05%	30	12,18%	8	17,31%	24	21,79%	4	19,87%	5	16,03%	21	11,54%	43	8,33%	43	8,33%	32	11,54%	6
9,62%	45	10,26%	30	7,05%	32	12,18%	17	17,31%	26	21,79%	6	19,87%	39	16,03%	22	11,54%	48	8,33%	48	8,33%	34	11,54%	8
10,90%	5	10,26%	32	7,05%	34	12,18%	25	17,95%	35	21,79%	7	21,79%	2	16,03%	24	11,54%	53	10,90%	53	10,90%	11	11,54%	15
10,90%	22	10,26%	34	7,05%	34	12,18%	32	18,59%	37	21,79%	8	21,79%	3	16,03%	26	11,54%	55	12,18%	55	12,18%	29	11,54%	17
10,90%	37	17,31%	1	7,05%	41	12,18%	38	19,23%	37	21,79%	10	21,79%	6	17,31%	1	12,18%	40	12,82%	40	12,82%	4	11,54%	23
11,54%	23	17,31%	2	7,05%	43	12,18%	43	19,87%	3	21,79%	11	21,79%	8	17,31%	8	17,31%	13	12,18%	45	13,46%	20	11,54%	25
12,18%	8	17,31%	3	7,05%	45	12,18%	50	19,87%	6	21,79%	12	21,79%	14	12,82%	36	13,46%	33	13,46%	38	13,46%	21	11,54%	30
12,18%	29	17,31%	4	7,05%	46	12,18%	53	19,87%	8	21,79%	13	21,79%	16	12,82%	38	13,46%	38	13,46%	38	13,46%	33	11,54%	32
12,18%	40	17,31%	5	7,05%	47	12,82%	6	19,87%	9	21,79%	14	21,79%	11	17,31%	18	14,10%	15	14,10%	15	14,10%	2	11,54%	36
12,18%	48	17,31%	6	7,05%	48	12,82%	15	19,87%	10	21,79%	15	21,79%	12	19,87%	12	14,10%	17	14,10%	17	14,10%	23	11,54%	38
12,82%	2	17,31%	8	7,05%	49	12,82%	20	19,87%	12	21,79%	16	21,79%	15	19,87%	15	14,10%	35	14,10%	19	14,10%	25	11,54%	39

tamsi		autoenc		ball		kmeans		knn		lof		lofrange		lpdd		mpm		mst		nparzen		parzen		sv	
	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	klaidos	kombi	
16,67%	17,71%	1	17,71%	69	16,67%	20	16,67%	60	16,67%	97	16,67%	97	16,67%	3	16,67%	97	16,67%	61	16,67%	60	16,67%	60	16,67%	60	
16,67%	17,71%	21	17,71%	77	16,67%	97	16,67%	97	17,71%	75	17,71%	10	17,71%	12	17,71%	60	16,67%	65	16,67%	65	16,67%	65	16,67%	97	
16,67%	17,71%	60	17,71%	84	17,71%	60	17,71%	65	18,75%	3	17,71%	19	18,75%	28	18,75%	62	18,75%	69	16,67%	69	16,67%	74	18,75%	59	
16,67%	17,71%	77	17,71%	90	18,75%	3	17,71%	74	18,75%	12	17,71%	20	18,75%	29	18,75%	64	18,75%	77	16,67%	77	16,67%	95	18,75%	62	
16,67%	17,71%	82	17,71%	96	18,75%	12	17,71%	95	18,75%	16	17,71%	27	18,75%	31	18,75%	99	18,75%	84	16,67%	84	16,67%	100	18,75%	64	
17,71%	17,71%	14	17,71%	98	18,75%	28	17,71%	100	18,75%	28	17,71%	40	18,75%	106	18,75%	33	18,75%	90	16,67%	90	16,67%	104	18,75%	90	
17,71%	17,71%	28	17,71%	99	18,75%	29	17,71%	104	18,75%	29	17,71%	45	19,79%	1	18,75%	59	18,75%	96	16,67%	96	16,67%	107	18,75%	92	
17,71%	17,71%	73	17,71%	100	18,75%	31	17,71%	107	18,75%	31	17,71%	52	19,79%	2	18,75%	64	18,75%	98	16,67%	98	16,67%	109	18,75%	94	
17,71%	17,71%	79	18,75%	56	18,75%	33	17,71%	109	18,75%	33	17,71%	55	19,79%	3	18,75%	72	18,75%	99	16,67%	99	16,67%	110	18,75%	99	
17,71%	17,71%	95	18,75%	57	18,75%	45	17,71%	110	18,75%	34	17,71%	82	19,79%	4	18,75%	90	18,75%	100	17,71%	100	17,71%	82	18,75%	106	
17,71%	17,71%	96	18,75%	58	18,75%	52	18,75%	3	18,75%	57	18,75%	3	19,79%	5	18,75%	92	18,75%	62	16,67%	62	16,67%	89	19,79%	1	
17,71%	17,71%	97	18,75%	59	18,75%	57	18,75%	12	18,75%	59	18,75%	12	19,79%	6	18,75%	93	18,75%	59	18,75%	59	18,75%	3	19,79%	2	
17,71%	17,71%	98	18,75%	61	18,75%	59	18,75%	28	18,75%	62	18,75%	28	19,79%	7	18,75%	94	18,75%	66	17,71%	66	17,71%	12	19,79%	3	
17,71%	17,71%	102	18,75%	63	18,75%	62	18,75%	29	18,75%	64	18,75%	29	19,79%	8	18,75%	99	18,75%	31	18,75%	31	18,75%	28	19,79%	4	
17,71%	17,71%	109	18,75%	64	18,75%	63	18,75%	31	18,75%	66	18,75%	31	19,79%	9	18,75%	106	18,75%	34	18,75%	34	18,75%	29	19,79%	5	
18,75%	18,75%	5	18,75%	65	18,75%	64	18,75%	33	18,75%	76	18,75%	33	19,79%	10	18,75%	108	18,75%	52	18,75%	52	18,75%	31	19,79%	6	
18,75%	18,75%	12	18,75%	68	18,75%	66	18,75%	57	18,75%	77	18,75%	34	19,79%	11	19,79%	1	18,75%	63	18,75%	63	18,75%	33	19,79%	7	
18,75%	18,75%	31	18,75%	73	18,75%	75	18,75%	59	18,75%	78	18,75%	57	19,79%	12	19,79%	2	18,75%	66	18,75%	66	18,75%	72	19,79%	8	
18,75%	18,75%	33	18,75%	75	18,75%	76	18,75%	62	18,75%	79	18,75%	59	19,79%	13	19,79%	4	18,75%	68	18,75%	68	18,75%	75	19,79%	9	
18,75%	18,75%	39	18,75%	76	18,75%	77	18,75%	64	18,75%	80	18,75%	60	19,79%	14	19,79%	5	18,75%	71	18,75%	71	18,75%	93	19,79%	10	


Nr. 5



Balta tekstūra




Geltona



Juoda tekstūra



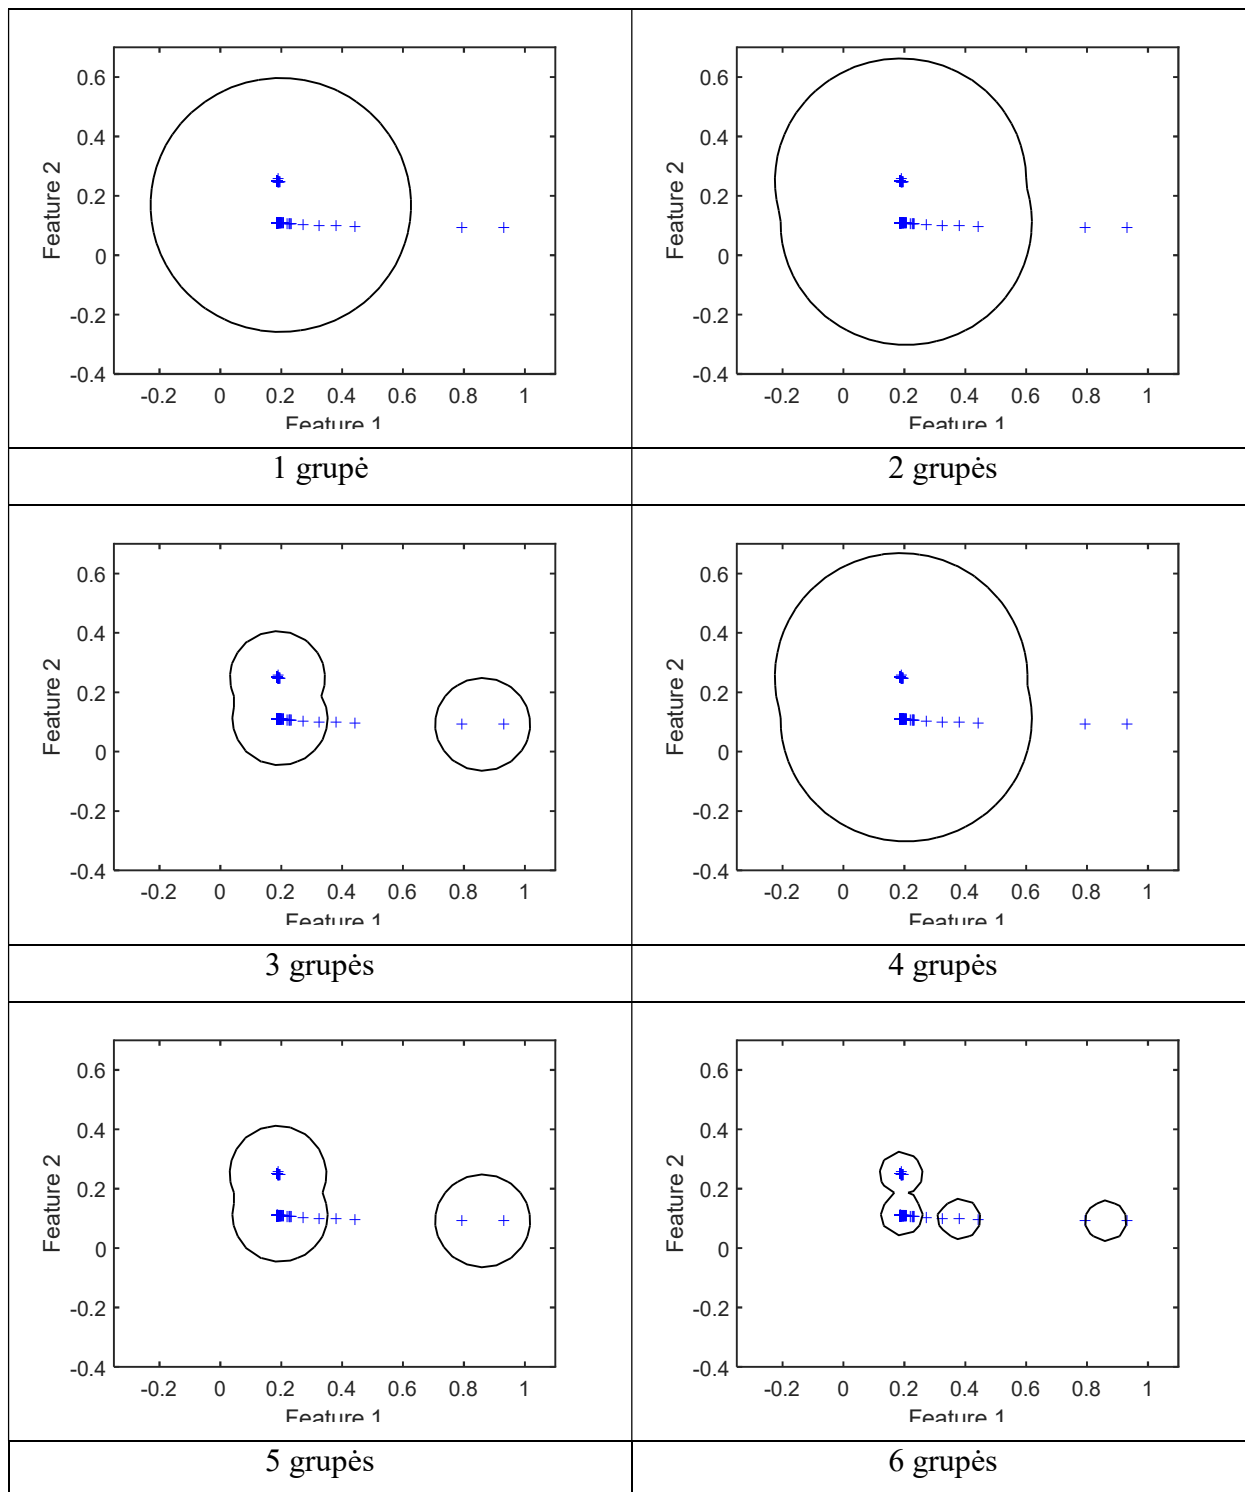
Mediena tanki

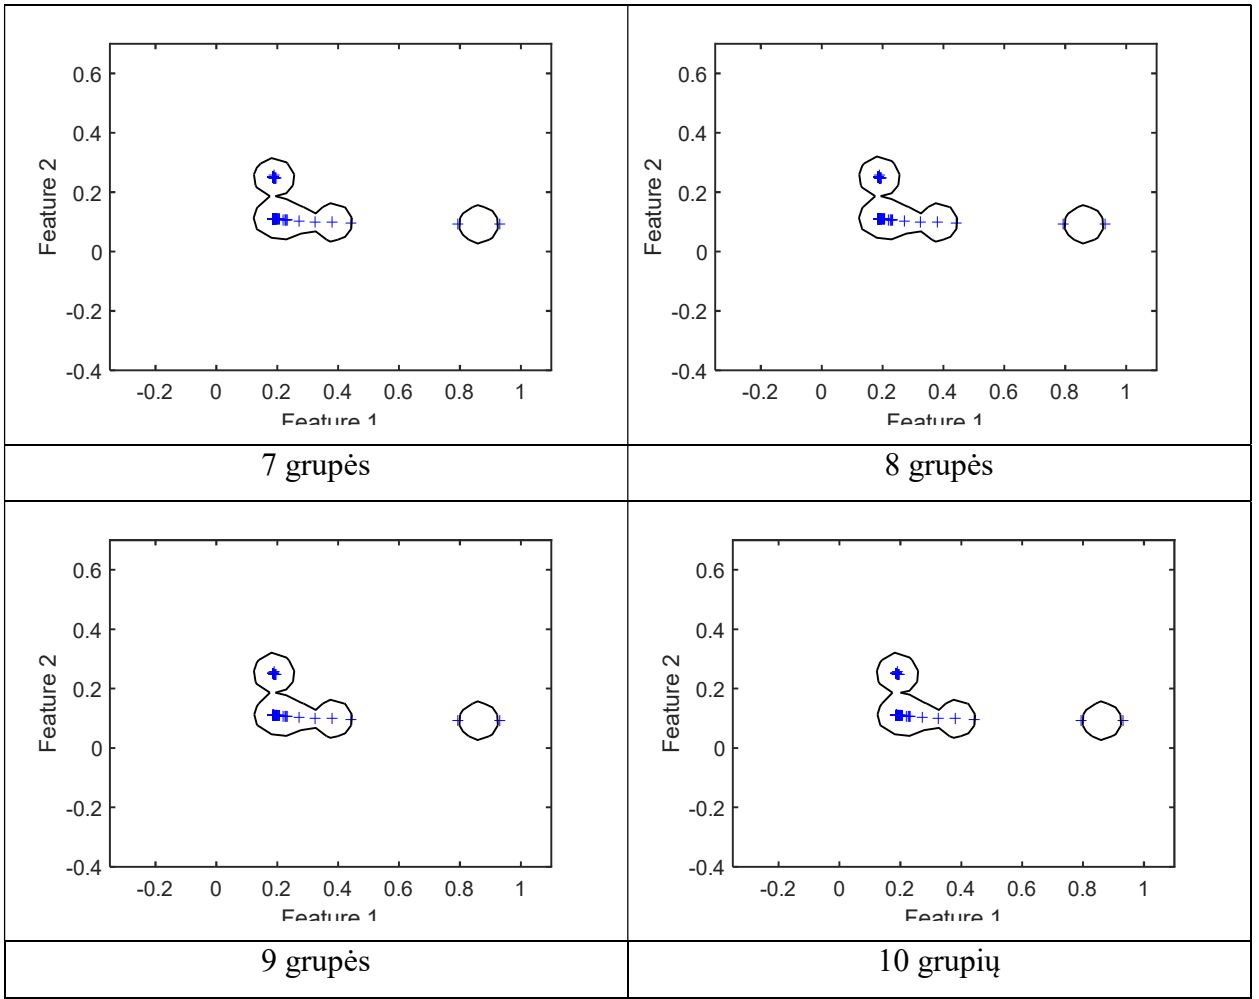


Tamsi

Nr. 6


K-vidurkis klasifikatoriaus duomenų grupavimas nurodant skirtingą kiekį grupių. Duomenys pagal plokštę „geltona“.







Nr. 7

K-asis artimiausias kaimynas klasifikatoriaus apimamos sritys.





K=4



K=5