



**KAUNO TECHNOLOGIJOS UNIVERSITETAS  
MATEMATIKOS IR GALTOS MOKSLŲ FAKULTETAS**

**Simona Skorupskaitė**

**NUOTOLINIO APTIKIMO VAIZDŲ ERDVINĖS  
KORELIACIJOS ANALIZĖ IR JŲ KLASIFIKAVIMAS**

Baigiamasis magistro projektas

**Vadovas**  
dr. M. Kavaliauskas

**KAUNAS, 2015**

**KAUNO TECHNOLOGIJOS UNIVERSITETAS**  
**MATEMATIKOS IR GALTOS MOKSLŲ FAKULTETAS**

**NUOTOLINIO APTIKIMO VAIZDŲ ERDVINĖS  
KORELIACIJOS ANALIZĖ IR JŲ KLASIFIKAVIMAS**

Baigiamasis magistro projektas  
Taikomoji matematika (kodas 621G10003)

**Vadovas**  
dr. M. Kavaliauskas

**Recenzentas**  
prof dr. J. Valantinas

**Projektą atliko**  
Simona Skorupskaitė

**KAUNAS, 2015**



KAUNO TECHNOLOGIJOS UNIVERSITETAS  
MATEMATIKOS IR GAMTOS MOKSLŲ FAKULTETAS

Simona Skorupskaitė  
Taikomoji matematika (621G10003)

Baigiamojo projekto „Nuotolinio aptikimo vaizdų erdvinės koreliacijos analizė  
ir jų klasifikavimas“

**AKADEMINIO SAŽININGUMO DEKLARACIJA**

2015m. Gegužės mėn. 22 d.

Kaunas

Patvirtinu, kad mano, **Simonos Skorupskaitės**, baigiamasis darbas tema „Nuotolinio aptikimo vaizdų erdvinės koreliacijos analizė ir jų klasifikavimas“ yra parašytas visiškai savarankiškai, o visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena darbo dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymu 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.

---

(studento vardas ir pavardė, įrašyti ranka)

---

(parašas)

Skorupskaitė S. Analysis of spatial variation and classification of remotely sensed images: Master's work in applied mathematics / supervisor dr. M. Kavaliauskas; Kaunas University of Technology, Faculty of Mathematics and Natural Sciences, Department of Applied Mathematics.

Kaunas, 2015. 45p.

## **SUMMARY**

Remotely sensed image classification is probably one of the most important strategic notion in the remotely sensed data research. Constructed thematic maps have been widely used for urban areas, forests, glaciers change detection, as well as for crop or soil evaluation.

In this work various spatial features have been analysed in order to rate the impact on classification of remotely sensed images. Classical models are build based on the spectral values of an image. However it has been criticised due to lack of spatial information. There is a review of the variogram and its application to remotely sensed image classification at the beginning of the paper. Variogram fitting is one of the methods of extracting texture parameters. In this case, coefficients of a theoretical model set up the spatial features. Secondly, image texture can be described by simple parameters derived from empirical variogram values. The relevance of the proposed features for remotely sensed image classification has been evaluated using satellite images of Kaunas city. The classifiers are constructed by support vector machines models with a particular kernel function. After the comparison of classification by different features the conclusion is that texture information description by derived variogram parameters is easier and more accurate. In addition, the most effective remotely sensed image classification was achieved by combining spatial and spectral features.



# TURINYS

ĮVADAS .....	6
Reikalavimai nuotolinio aptikimo vaizdų klasifikavimo metodams, programinei įrangai ir atliekamiems tyrimams .....	6
Darbe sprendžiami uždaviniai.....	7
1. LITERATŪROS APŽVALGA.....	7
1.1. Nuotolinio aptikimo vaizdų struktūra .....	7
1.2. Erdvinės statistikos taikymas vaizdų klasifikavime .....	8
1.3. Statistinis objekto atpažinimas.....	9
1.4. Nuotolinio aptikimo vaizdų klasifikavimui taikomi matematiniai metodai .....	10
2. MEDŽIAGOS IR TYRIMŲ METODAI.....	12
2.1. Erdvinio kintamumo aprašymas variograma .....	12
2.2.1. Empirinės variogramos modeliavimas.....	13
2.2.2. Variogramos funkciją aprašantys dydžiai .....	14
2.3. Atraminių vektorių klasifikatorius.....	16
2.3.1. Klasifikatoriaus parametrų parinkimas .....	18
2.3.2. Daugiaklasis klasifikavimas atraminių vektorių klasifikatoriumi .....	19
2.4. Klasifikuoto vaizdo apdorojimas .....	20
2.5. Empirinis klasifikavimo tikslumo vertinimas.....	20
3. NUOTOLINIO APTIKIMO VAIZDO KLASIFIKAVIMAS.....	21
3.1. Tiriamas nuotolinio aptikimo vaizdas.....	21
3.2. Klasifikavimas pagal variogramos modelio koeficientus .....	25
3.3. Klasifikavimas pagal variogramos funkcijos parametrus .....	28
3.4. Rezultatų aptarimas.....	33
4. NUOTOLINIO APTIKIMO VAIZDO KLASIFIKAVIMUI TAIKOMA PROGRAMINĖ ĮRANGA.....	35
4.3. PROGRAMOS TAIKYMO APRAŠYMAS .....	36
IŠVADOS .....	37
LITERATŪRA .....	38
1 PRIEDAS. MATLAB FUNKCIJOS .....	40

## IVADAS

Nuotolinio aptikimo (angl. *remote sensing*) vaizdų analizė suteikia galimybę gauti informacijos apie žemės paviršių iš nuotolinio stebėjimo duomenų. Dėka prieinamų aukštos rezoliucijos vaizdų, tiek stambūs žemės paviršiai (miškai, upės, miestai, pievos ir t.t.), tiek smulkūs fiziniai objektai (keliai, pastatai, tiltai, automobiliai ir t.t.) gali būti nesudėtingai identifikuojami žmogaus akimi. Pagrindinis nuotolinio aptikimo vaizdų analizės tikslas yra teminio žemėlapių kūrimas, klasifikuojant tokius vaizdus. Kitaip tariant, aptikto vaizdo dalims yra suteikiama fizinės aplinkos interpretaciją.

Tokiu būdu siekama išsiaiškinti žemės paviršiaus, urbanizuotų teritorijų, miškų, ledynų, kintamumą, taip pat nustatyti laukiamo derliaus kiekį ar stebėti žemės drėgnumą,

Dauguma klasifikavimo metodų remiasi statistiniais metodais, kur skirtingų žemės paviršių taškai atskiriami vieni nuo kitų pagal sprendimo priėmimo taisyklę bei remiantis duomenų padėtimi savybių erdvėje.

Nuotolinio aptikimo vaizdų struktūra tampa vis sudėtingesnė, nes naujos technologijos perteikia itin didelės raiškos vaizdus. Todėl vaizdo elementų spektrinės informacijos nepakanka jiems kokybiškai atpažinti, o erdvinių priklausomybių vertinimas klasifikuojant vaizdą tampa itin aktualus.

Šiame darbe analizuojamas vaizdų atpažinimas panaudojant tekstūros charakteristikas. Variograma yra pagrindinis įrankis geostatistiniams tyrimams. Variogramos funkcija aprašo erdvinį vaizdo kintamumą – nurodo ryši tarp variacijos ir erdvinio atskyrimo. Erdvinės variacijos plačiai naudojamos nuotolinio aptikimo vaizdų analizėje kaip tekstūros parametru, naudojamu klasifikavimui, gavimo įrankis.

Vaizdų klasifikavimui taikomas atraminių vektorių sistemos metodas. Šio klasifikatoriaus tikslas yra atraminių vektorių, kurie vienareikšmiškai apibrėžia klases atskiriančią optimalią hiperplokštumą, radimas mokymo imtyje.

### **Reikalavimai nuotolinio aptikimo vaizdų klasifikavimo metodams, programinei įrangai ir atliekamiems tyrimams**

Vaizdų klasifikavimo modelių kūrimas reikalauja itin galingos bei dinamiškos programinės įrangos. Sistema turi sugebėti skaityti vaizdų spektrinę informaciją iš išorinių šaltinių, teikti efektyvius skaičiavimo metodus, sugebėti valdyti didelius duomenų rinkinius bei teikti pažangių statistinių metodų taikymo galimybes.

Tyrimai atliekami norint suteikti optimalią nuotolio atpažinimo vaizdo interpretaciją. Tyrime naudojami duomenys turi sudaryti reprezentatyvią vaizdą sudarančių erdvinių ir

spektrinių klasių dalį. Taip pat naudojamų vaizdų raiška turi būti pritaikyta ir optimizuota erdvinį parametrų išgavimui. Į analizę įtraukiami kintamieji turi būti korektiški ir kuo tiksliau vertinti spektrinę bei tekstūros informaciją.

## **Darbe sprendžiami uždaviniai**

**Pagrindinis darbo tikslas.** Neprametrinio klasifikavimo taikymas nuotolinio aptikimo vaizdams, atsižvelgiant į analizuojamų vaizdų spektrinę ir erdvinę informaciją. Taip pat programinės įrangos sukūrimas klasifikavimo analizės metodams įgyvendinti bei gautai informacijai pateikti.

### **Sprendžiami uždaviniai:**

- Nuotolinio aptikimo vaizdų klasifikavimui ir erdvinį parametrų išgavimui taikomus populiarius statistinės matematikos metodų ir modelių apžvalga;
- Pasirinktų modelių programinis realizavimas;
- Taikant realizuotus modelius bei programinę įrangą atlikti vaizdo klasifikavimą;
- Palyginti įvairių spektrinių ir tekstūros parametrų bei jų kombinacijų taikymo efektyvumą klasifikuojant nuotolinio aptikimo vaizdus;
- Gautus apibendrintus tyrimo rezultatus pateikti lentelių bei grafikų pavidalu. Pateikti išvadas bei rekomendacijas tolimesniems darbams.

## **1. LITERATŪROS APŽVALGA**

### **1.1. Nuotolinio aptikimo vaizdų struktūra**

Žemės paviršiaus nuotolinio aptikimo vaizduose atsispindi įvairių ilgių bangos <sup>[9]</sup>. Tačiau, prieš patenkant į aptikimo sensorių, kai kurios bangos yra išskaidomos atmosferoje. Todėl užfiksuotame vaizde mėlyną spalvą ( $0.4-0.5\mu m$ ) nešanti banga yra nuslopinta. Be reikšmingo atmosferos filtravimo, žemės paviršių nuotolinio aptikimo vaizduose charakterizuoja žalių ( $0.5-0.6\mu m$ ), raudonų ( $0.6-0.7\mu m$ ) ir artimųjų IR ( $0.7-5\mu m$ ) spindulių bangos. Be to, šių ilgių intervalų bangos suteikia pakankamai informacijos apie žemės paviršiaus pobūdį. Pavyzdžiui, chlorofilas puikiai sugeria matomą raudoną spalvą, o infraraudonieji spinduliai gali informuoti apie vaizde fiksuotus augalų lapus. Ilgesnės nei  $5\mu m$  bangos vadinamos viduriniaisiais IR spinduliais ( $5-40\mu m$ ) ir tolimaisiais IR spinduliais arba šiluminiais spinduliais ( $40-200\mu m$ ). Pastarieji ypač naudingi paviršiuje stebint ne tik pramoninės veiklos šilumos išsidėstymą, bet ir analizuojant dirvožemio drėgnumą.

Spektrinis modelis (angl. *spectral response patterns*) aprašo skirtingų spektrų energijos lygį <sup>[9]</sup>. Supaprastintas spektrinis modelis aprašo trijų pagrindinių spalvų (mėlynos, raudonos ir

žalios, kitaip RGB) spektrų intensyvumus. Šiais trimis spektrais sukuriama pagrindinės žmogaus interpretuojamos spalvos.

Bendru atveju, pagrindinės palydovinių duomenų charakteristikos yra erdvinė raiška (angl. *spatial resolution*) ir spektrinė raiška (angl. *spectral resolution*)<sup>[17]</sup>. Erdvinė raiška nurodo žemės dydį, kuris fiksuojamas vienoje vaizdo duomenų reikšmėje. Spektrinė rezoliucija aprašo sensoriaus fiksuojamas spektrines juostas ir jų pločius.

Vaizdai dažniausiai saugomi rastiniu modeliu – kuomet erdvė vaizduojama grupe sričių (dažniausiai kvadrato formos), esančių šalia vienas kito<sup>[22]</sup>.

Interpretuojant nuotolinio aptikimo vaizdus atsižvelgiama į daugelį charakteristikų: spalvą, struktūrą, dydį, formą, raštus, kontekstą ir panašiai<sup>[9]</sup>. Tačiau, naudojant kompiuterines priemones, dažnai pakanka spalvas aprašančių parametrų, kitaip tariant, spektrinio modelio. Taigi nuotolinio vaizdų aptikimui naudojami keleto spektrų (angl. *multispectral*) sensoriai, kurie fiksuoja spektrines juostas (angl. *spectral bands*). Praktinės analizės metodais, pavyzdžiui, pagrindinių komponentų analize, įrodyta, kad daugiausiai informacijos apie aplinkos pobūdį suteikia artimųjų infraraudonųjų bei raudonų bangų spektrinės juostos<sup>[22]</sup>. Taigi, dauguma nuotolinio aptikimo sensorių, naudojamų žemės paviršiaus stebėjimui, fiksuoja būtent šių spektrų bangas. Be šių bangų, fiksuojant ir žalio spektro juostą, sukuriama vadinama klaidinga spalvų kompozicija – spalvotas vaizdas, kuris puikiai perteikia kultūrinį kraštovaizdį, bei natūralius augmenijos pavišius.

Hiperspektriniai (angl. *hyperspectral*) sensoriai fiksuoja žymiai daugiau spektrinių juostų<sup>[7]</sup>. Šios juostos padengia multispektrinių sensorių bangų ilgių intervalą, tačiau atskiros juostos yra žymiai siauresnių intervalų. Todėl hiperspektrinių vaizdų analizėje svarbus uždavinys susijęs su daugiausiai informacijos nešančių spektrinių juostų išrinkimu, t.y. stengiamasi pašalinti perteklinę vaizdo informaciją.

Klasifikuojant nuotolinio aptikimo vaizdus galima išskirti du bendrinius modelius:

- Multispektrinio vaizdo atveju, kai vaizdo spektrinė rezoliucija žema, svarbu vaizdo duomenis papildyti erdvine informacija.
- Hiperspektrinio vaizdo atveju, svarbu pašalinti perteklines spektrines juostas.

## 1.2. Erdvinės statistikos taikymas vaizdų klasifikavime

Nuotolinio aptikimo vaizdų analizėje klasifikavimas yra apibūdinamas kaip teminių žemėlapių sudarymo iš žemės paviršiaus nuotraukų procesas. Tradicinis vaizdo klasifikavimas atliekamas klasifikuojant kiekvieną vaizdo pikselį pagal jo spektrinę informaciją. Tačiau toks klasifikavimas yra plačiai kritikuojamas, nes tuomet vaizdo elementai yra laikomi statistiškai nepriklausomais nuo šalia esančių elementų ir praleidžiama galimai svarbi erdvinė informacija

apie šalia esančių pikselių spektrines reikšmes <sup>[20,25]</sup>. Skaitmeniniame žemės vaizde, ypač aukštos rezoliucijos, tam tikro pikselio spektrinių juostų intensyvumų reikšmės yra įtakojamos aplink esančių žemės plotų.

Galimi vaizdo tekstūros vertinimo metodai yra šie <sup>[26]</sup>:

- Furjė transformacijos;
- Pilkumo lygių pasikartojimo matricės;
- Semivariacija.

Palyginus vaizdo klasifikavimo tikslumą naudojant skirtingus erdvės vertinimo metodus tikslesnis vaizdo atpažinimas gaunamas į modelį įtraukiant variogramos parametrus negu klasifikuojant pagal pilkumo lygio pasikartojimų matricos parametrus <sup>[2,4]</sup>.

Variograma aprašo priklausomybę tarp stebėjimų esant skirtingiems atstumams tarp jų, t.y. koreliacijos tarp imties stebėjimo porų mažėjimą, didėjant tarpusavio atstumui. Variogramų taikymą nuotolinio aptikimo vaizdų analizėje pristatė <sup>[19,28,29]</sup>. Ji suteikia informacijos apie erdvinio kintamumo dydį ir pobūdį.

<sup>[3]</sup> vaizdų klasifikavimui naudojo empirinės variogramos reikšmes, o kiekvienam pikseliui klases priskyrė pagal minimalų atstumą. Atstumu laikoma skirtumų tarp apskaičiuotų variogramos reikšmių ir kiekvieną klasę charakterizuojančios variogramos reikšmių suma.

<sup>[1]</sup> vaizdo erdvines priklausomybes vertino taikant variogramą. Savo darbe autoriai aprašė galimą dvejetainę šios funkcijos pritaikymą. Pirmuoju atveju, variogramos reikšmės naudojamos tiesiogiai, apibrėžus du skirtingo dydžio langus. Pirmame, didesniame lange, įterpiami mažesni langai. Mažesnių langų zonose apskaičiuojamos variogramų reikšmės įvairiems pikselių intervalams. Toliau, kaip tekstūros parametrai, yra naudojami apskaičiuotų variogramų vidurkis ir standartinis nuokrypis. Antruoju atveju, autoriai naudojo variogramos, modeliuotos empirinei variogramai, parametrus. Autoriai pabrėžia, kad automatizuotas modelio parinkimas empirinei variogramai yra sudėtingas ir nepatikimas, dėl skirtingų modelių netinkamumo analizuojamoms įvairioms vaizdo zonoms.

<sup>[8]</sup>, <sup>[2]</sup> vaizdų klasifikavimui, atsižvelgiant į jų tekstūrą, pritaikė parametrus, apskaičiuotus iš empirinės variogramos.

### 1.3. Statistinis objekto atpažinimas

Skaitmeninių vaizdų apdorojimą galima skaidyti į keturias pagrindines operacijas: vaizdo atkūrimą (angl. *image restoration*), vaizdo savybių išryškinimą (angl. *image enhancement*), vaizdo klasifikavimą (angl. *image classification*) ir vaizdo transformavimą (angl. *image transformation*) <sup>[9]</sup>. Atkuriant vaizdą stengiamasi optimizuoti vaizdo sudarymo

procesą, pašalinti netikslumus, atsirandančius dėl atmosferos poveikio bei tolumo atstumo. Išryškinant vaizdo savybes siekiama sudaryti kuo įmanoma tikslesnį skaitmeninį žemės paviršiaus atkartojimą. Klasifikavimas yra viena pagrindinių skaitmeninio vaizdo apdorojimo operacijų, kuomet vaizdui suteikiama interpretacija. Skaitmeninio vaizdo transformavimas siejamas su matematiniu jo spektrareikšmių apdorojimu sudarant naują vaizdą.

Vaizdų analizėje objektų klasifikavimas dar vadinamas objektų atpažinimu (angl. *pattern recognition*). Klasifikuojami objektai įgauna prasmę priklausomai nuo atpažinimo uždavinio konteksto. Bendru atveju vaizdo klasifikavimo metodai skirstomi į: be apmokomosios imties arba su apmokomąja imtimi.

Klasifikuojant be apmokomosios imties iš anksto nėra žinoma jokia informacija apie dominančias klases. Šiuo atveju duomenys yra suskaidomi į dažniausiai pasikartojančias, natūraliai susidariusias spektrų grupes, vadinamas klasteriais <sup>[24]</sup>.

Klasifikavime su apmokomąja imtimi yra naudojami vaizdų fragmentai su iš anksto jiems apibrėžtomis statistinėmis charakteristikomis <sup>[24]</sup>. Klasifikuojant pirmiausiai yra apibrėžiamos klasifikavimo klasės, t.y. žemės paviršiaus tipai, kurie labiausiai domina. Toliau programinės sistemos pagalba yra įvertinami skirtingų klasių parametrai, tokie kaip spektrinių juostų vidurkis, dispersija ar kovariacija tarp skirtingų juostų. Klases aprašius parametrais, norimas vaizdas klasifikuojamas pagal geriausiai jį atitinkančias savybes. Vaizdo priklausomybę vienai ar kitai klasei įvertina vadinami klasifikatoriai. Klasifikatorius galima skirstyti į griežtus, kuomet vaizdas priskiriamas vienai konkrečiai klasei, arba negriežtus, kuomet klasifikuojamui vaizdui įvertinamos tikimybės priklausyti skirtingoms klasėms. Klasifikavime be apmokomosios imties, dažnai vadinamame klasterizavimu, yra identifikuojami dažniausiai pasikartojantys vaizdo paviršių tipai, kuriems vėliau suteikiama interpretacija.

#### **1.4. Nuotolinio aptikimo vaizdų klasifikavimui taikomi matematiniai metodai**

Šiame darbe yra nagrinėjamos multispektrinių vaizdų erdviųjų parametrų klasifikavimo galimybės. Dažnai taikytinas minimalaus atstumo klasifikatorius, kuris naudoja Euklido atstumo matą, arba maksimalaus tikėtimumo metodas su Mahalonobio metrika <sup>[1,3]</sup>. Tačiau šiuose darbuose klasifikavimas atliekamas kiekvienam vaizdo elementui, todėl neatsižvelgiama į erdvinę informaciją.

Tiek multispektrinių, tiek hiperspektrinių vaizdų klasifikavimui vis dažniau naudojami parametriniai metodai. Pastaruoju metu nuotolinio aptikimo vaizdų klasifikavimui išskiriami neparametriniai metodai, pateikiami 1.1 lentelėje <sup>[26]</sup>. Neparametrinių metodų privalumas –

nedaroma prielaida apie analizuojamų duomenų skirstinį. Taip pat lentelėje pateikiami apibendrinti kitų metodų privalumai bei trūkumai.

**1.1 lentelė. Vaizdų klasifikavimo metodai, jų privalumai ir trūkumai**

<b>Metodas ir klasifikatoriaus struktūra</b>	<b>Metodo privalumai</b>	<b>Metodo trūkumai</b>
Dirbtiniai neuroniniai tinklai <ul style="list-style-type: none"> <li>• daugiasluoksniai perceptronai</li> <li>• save apsimokantys Kohoneno žemėlapiai</li> <li>• Hopfieldo tinklai</li> </ul>	<ul style="list-style-type: none"> <li>• Galima pasiekti nirimai didelį tikslumą – klasifikatoriaus tikslumas didinamas naudojant vis daugiau stebėjimų.</li> </ul>	<ul style="list-style-type: none"> <li>• Tinklo paslėpti neuronų sluoksniai nėra žinomi.</li> <li>• Tinklo apmokymui didelę įtaką daro apmokymo imties dydis.</li> </ul>
Atraminių vektorių sistemos <ul style="list-style-type: none"> <li>• tiesinis klasifikatorius</li> <li>• branduolinės funkcijos klasifikatorius</li> </ul>	<ul style="list-style-type: none"> <li>• Sugeba tinkamai apsimokyti esant nedideliai apmokomajai imčiai; lyginant su klasikiniiais metodais gaunamas tikslesnis klasifikavimas <sup>[16]</sup></li> <li>• Teoriškai gali gerai apdoroti dididelės dimensijos ir didelės imties duomenis <sup>[18]</sup>.</li> </ul>	<ul style="list-style-type: none"> <li>• Klasikiniu atveju sudaromos binarinės klasės <sup>[26]</sup></li> <li>• Branduolio funkcijos parinkimas apsunkina metodo taikymą</li> <li>• Klasifikavimo ir mokymosi etapo skaičiavimai yra polinominio sudėtingumo, priklausomai nuo duomenų dimensijos <sup>[11]</sup>.</li> </ul>
Sprendimų medžiai <ul style="list-style-type: none"> <li>• sprendimų medis</li> <li>• atsitiktinis miškas</li> </ul>	<ul style="list-style-type: none"> <li>• Suteikia klasifikavimo taisyklių rinkinį.</li> </ul>	<ul style="list-style-type: none"> <li>• Jautrumas duomenų kokybei bei skirtingų klasių apmokymo imties dydžiui. Klasifikatorius gali būti itin pritaikyti apmokomajai imčiai, todėl testavimo imties klasifikavimas gali būti ne toks tikslus <sup>[15]</sup>.</li> </ul>

<sup>[21]</sup> darbe lyginti neparimetrinio klasifikavimo metodai, klasifikavimui naudojant tropinės ekosistemos vaizdą, fiksuotą įvairiais sensoriais. Tarp darbe bandytų klasifikatorių didžiausią tikslumą pasiekė atraminių vektorių sistemos klasifikatorius. Taip pat rezultatai parodė, kad šio klasifikatoriaus tikslumas, lyginant su kitų neparimetrinių metodų tikslumu, padidėja, padidinus spektrinių juostų kiekį ir spektrinę raišką.

## 2. MEDŽIAGOS IR TYRIMŲ METODAI

### 2.1. Erdvinio kintamumo aprašymas variograma

Šiame darbe nuotolinio aptikimo vaizdų erdvinės priklausomybės analizuojamos taikant geostatistikos metodus. Geostatistika nagrinėja erdviųjų duomenų koreliuotumą. Pagrindinis geostatistikos įrankis vertina erdvinės kovariacijos funkciją (autokoreliacijos kryptį, pavidalą ir ribas), kitaip vadinamą variograma. Pagrindinė geostatistikos prielaida yra apie erdviųjų procesų sudėtį: juos sudaro determinuota ir kintanti komponentės (2.1). Determinuotos komponentės gali būti globalūs arba lokalūs trendai. Kintanti komponentė yra formuojama atsitiktinai ir pasižymi koreliuotumu.

$$z(\mathbf{x}) = \mu_v + \varepsilon(\mathbf{x}); \quad (2.1)$$

čia  $\mu_v$  yra vidurkis,  $\varepsilon(\mathbf{x})$  – atsitiktinė komponentė, pasižyminti erdvine priklausomybe, kuriai galioja  $E[\varepsilon(\mathbf{x})] = 0$  sąlyga, o variacija apibrėžiama:

$$\text{var}[\varepsilon(\mathbf{x}) - \varepsilon(\mathbf{x} + \mathbf{h})] = E \left[ (\varepsilon(\mathbf{x}) - \varepsilon(\mathbf{x} + \mathbf{h}))^2 \right] = 2\gamma(\mathbf{h}); \quad (2.2)$$

čia  $\mathbf{h}$  yra atstumo vektorius, turintis ilgį ir kryptį, skiriantis stebėjimus  $\mathbf{x}$  ir  $\mathbf{x} + \mathbf{h}$ , dydis  $\gamma(\mathbf{h})$  vadinamas semivariacija. Semivariacija priklauso nuo poslinkio tarp pikselių analizuojamame lange dydžio.

Empirinė variograma vertinama tam tikro dydžio vaizdo langeliui, tariant, kad kiekvieno langelio pikselio reikšmė yra erdvinio proceso realizacija. Tolydžiam kintamajam empirinė variograma (angl. *experimental variogram*) apibrėžiama kaip kvadratinių skirtumų tarp  $\mathbf{h}$  vėlavimų pusė vidurkio. Empirinė variograma (kartais vadinama semivariograma arba tiesiog paprastai - variograma) yra vertinama  $\alpha = 1, 2, \dots, P(\mathbf{h})$  stebėjimo poroms  $\{z_v(\mathbf{x}_\alpha), z_v(\mathbf{x}_\alpha + \mathbf{h})\}$ . Stebėjimų padėtis  $\{\mathbf{x}, \mathbf{x} + \mathbf{h}\}$  skiria fiksuotas vėlavimo dydis  $\mathbf{h}$ . Statistinis variogramos įvertinimas dažnai gaunamas apibendrinant empirinės variogramos centrą, t.y. empirinė variograma yra suvidurkinama:

$$\gamma(\mathbf{h}) = \frac{1}{2P(\mathbf{h})} \sum_{i=1}^{P(\mathbf{h})} (z(\mathbf{x}_i) - z(\mathbf{x}_i + \mathbf{h}))^2. \quad (2.3)$$

Teoriškai empirinė variograma apibrėžtame lange skaičiuojama įvairiomis kryptimis. Tuomet ji vadinama įvairiakrypte. Tačiau skaičiavimai gali būti supaprastinami vertinant tik kelias pasirinktas kryptis <sup>[2]</sup>. Taip pat, vietoj kelių kryptų, galima vertinti vieną, kurios variogramos reikšmės turės didžiausią kintamumą <sup>[8]</sup>.

Nors empirinis variogramos vertinimas nėra sudėtingas, tačiau rezultatų pritaikymas automatizuotam klasifikavimui nėra pilnai galimas <sup>[12]</sup>. Išskiriamos šios pagrindinės problemos:

- Optimalaus lango dydžio nustatymas;



- Parametrų išskyrimas;
- Tikslinių duomenų parinkimas (klasifikatoriaus apmokymui ir klasifikavimo tikslumo vertinimui).

Empirinė variograma yra skaičiuojama tam tikro dydžio langeliui ar pikselių segmentui. Slenkančio objekto dydis turi būti pakankamai didelis, kad jame būtų užfiksuota kintanti tekstūra, taip pat ne per daug didelis – jis turi būti homogeninis žemės paviršiaus klasių atžvilgiu. Variogramos reikšmių kiekis priklauso nuo analizėje naudojamo langelio (objekto) dydžio. Tuomet laikoma, kad apskaičiuoto langelio variogramos reikšmės yra centrinio to langelio pikselio tekstūros matai.

### 2.2.1. Empirinės variogramos modeliavimas

Variogramos modelis yra parametrinė kreivė, kuri modeliuojama variogramos empirinėms reikšmėms. Variogramos reikšmės gali būti modeliuojamos tik tam tikromis teigiamai apibrėžtomis funkcijomis. Žinomi ir praktikoje taikomi modeliai:

- Sferinis modelis

$$\gamma_{sph}(h) = \begin{cases} c \cdot \left(1.5 \frac{h}{a} - 0.5 \left(\frac{h}{a}\right)^3\right), & 0 \leq h \leq a; \\ c, & h > a; \end{cases} \quad (2.4)$$

- Eksponentinis modelis

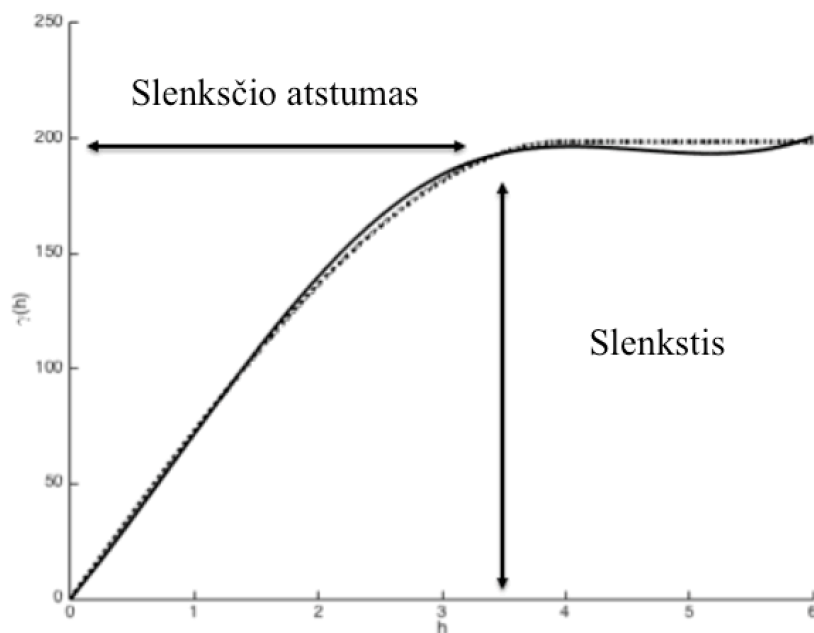
$$\gamma_{exp}(h) = c \cdot \left(1 - \exp\left(-3 \frac{h}{a}\right)\right); \quad (2.5)$$

- Tiesinis modelis

$$\gamma_t(h) = b \cdot h; \quad (2.6)$$

čia  $c$  yra slenkstis (angl. *sill*),  $a$  - slenkščio atstumas (angl. *range*) ir  $b$  - nuolydis (angl. *slope*). Taigi variogramą galima įprasminti šiais funkcijų koeficientais (2.1 pav.). Nustatyta, kad šie ir kiti (išvestiniai) parametrai yra naudingi vertinant vaizdo tekstūrą.

Variograma gali būti modeliuojama įvairiais būdais. Tarp jų yra maksimalaus tikėtinumo (angl. *maximum likelihood, ML*), apriboto maksimalaus tikėtinumo (angl. *restricted maximum likelihood, REML*), mažiausių kvadratų su svoriais (angl. *weighted least squares, WLS*) ir kiti metodai. Maksimalaus tikėtinumo metodai naudoja prielaidą apie variogramos reikšmių skirstinį. Įrodyta, kad mažiausių kvadratų su svoriais metodas yra priimtinausias metodas variogramos modeliavimui, ypač atsižvelgiant į tai, kad metodo rezultatai pasižymi pastovumu įvairiose situacijose <sup>[30]</sup>.



**2.1 pav.** Variogramos iliustracija, vientisa linija žymi empirinę variogramą, punktyrinė linija - sferinį modelį

Mažiausių kvadratų su svoriais metodu stengiamasi minimizuoti modeliuojamos funkcijos liekanų kvadratų svorinę sumą:

$$\sum_h w_h (\gamma(\mathbf{h}) - \gamma(\mathbf{h}, \boldsymbol{\theta}))^2; \quad (2.7)$$

čia  $\gamma(\mathbf{h})$  yra empirinė variograma,  $\gamma(\mathbf{h}, \boldsymbol{\theta})$  - variogramos modelis, kur  $\boldsymbol{\theta}$  yra modelio koeficientų vektorius. Modeliuojamos variogramos svoriai gali būti apskaičiuojami pagal aproksimuotas variogramos reikšmių variacijas<sup>[6]</sup>:

$$w_h = \frac{1}{Var(\gamma(\mathbf{h}))}; \quad (2.8)$$

čia

$$Var(\gamma(h)) \approx \frac{2}{P(h)} (\gamma(h))^2. \quad (2.9)$$

Tokie svoriniai daugikliai suteikia prioritetą empirinės variogramos reikšmėms prie mažų poslinkių  $|\mathbf{h}|$  - kuo variogramos reikšmė arčiau  $\mathbf{h} = \mathbf{0}$ , tuo svorio reikšmė didesnė.

### 2.2.2. Variogramos funkciją aprašantys dydžiai

Variogramą, kaip vieno kintamojo funkciją, galima charakterizuoti įvairiais parametrais. Tokios charakteristikos skaičiuojamos panaudojant langelio statistinius matavimus ir variogramos reikšmes. Tokiu atveju, kai empirinė variograma turi lokalių maksimumų ir minimumų, parametrai papildomi paprastais santykiniais dydžiais tarp pirmo maksimumo ir pirmos variogramos reikšmės ir panašiai. Šie parametrai skirstomi į tris kategorijas:

- Bendrieji parametrai;

- Pirmo maksimumo parametrai;
- Antro maksimumo parametrai.

[2] analizavo šių išvestinių parametru koreliuotumą ir įtaką žemės paviršiaus klasių diskriminavime pagal tekstūrą. Remiantis literatūros šaltinyje pateikiamais rezultatais, daugiausiai informacijos apie variogramos funkciją suteikiantys parametrai toliau žymimi (\*). Atliekant parametru skaičiavimus tariama, kad  $\gamma_i = \gamma(h_i)$ , o erdvinio atskyriamumo intervalai yra išsidėstę vienodu atstumu. Tuomet eksperimentinės variogramos reikšmės gali būti išreiškiamos:

$$\{(h, \gamma_1), (2h, \gamma_2), \dots, (nh, \gamma_n)\}. \quad (2.10)$$

Bendrieji parametrai skaičiuojami panaudojant langelio statistinius matavimus ir variogramos reikšmes.

1. Santykis tarp langelio reikšmių dispersijos ir vienetinio nuotolio semivariacijos tarp pikselių  $\gamma_1$ :

$$BP_1 = \frac{D}{\gamma_1}. \quad (2.11)$$

2. Nuolydis tarp pirmųjų dviejų variogramos reikšmių:

$$*BP_2 = \frac{\gamma_2 - \gamma_1}{h}. \quad (2.12)$$

3. Funkcijos išgaubtumo dydį apie mažų intervalų variogramos reikšmes galima įvertinti:

$$BP_3 = \frac{\gamma_4 - 2\gamma_3 + \gamma_2}{h^2}. \quad (2.13)$$

Kadangi variogramos funkcijos slenkstis artėja prie langelio dispersijos, todėl  $BP_1$  nurodo santykį tarp erdvinės priklausomybės ilgų ir trumpų atstumų atžvilgiu.  $BP_2$  suteikia informacijos apie artimų sprektnių reikšmių kintamumo dydį. Šie abu parametrai susiję su vaizdo pilkumo lygių homogeniškumu.  $BP_3$  įvertina funkcijos išgaubtumo dydį apie mažų intervalų variogramos reikšmes. Teigiama parametro reikšmė nurodo įgaubtą kreivę. Tai reiškia, kad analizuojamame langelyje artimi pikseliai yra homogeniniai. Kitu atveju, neigiamas parametras rodo, kad kreivė išgaubta, o langelio artimi pikseliai yra heterogeniniai.

Pirmo maksimumo parametrai skaičiuojami, atsižvelgiant į empirinės variogramos lokalius maksimumus.

4. Variogramos pirmo lokalaus maksimumo reikšmė:

$$MP_1 = \gamma_{max_1}. \quad (2.14)$$

5. Variogramos reikšmių iki pirmo lokalaus maksimumo vidurkis:

$$*MP_2 = \frac{1}{max_1} \sum_{i=1}^{max_1} \gamma_i. \quad (2.15)$$

6. Variogramos reikšmių iki pirmo lokalaus maksimumo dispersija:

$$*MP_3 = \frac{1}{max_1} \sum_{i=1}^{max_1} (\gamma_i - MP_2)^2. \quad (2.16)$$

7. Santykis tarp vienetinio intervalo langelio semivariacijos ir variogramos reikšmių iki pirmo lokalaus maksimumo vidurkio:

$$*MP_4 = \frac{\gamma_{max_1}}{MP_2}. \quad (2.17)$$

Pirmo lokalaus maksimumo reikšmė  $MP_1$  apytiksliai parodo variogramos slenksčio atstumą. Monotoninės variogramos funkcijos atveju, šiuo dydžiu laikomas analizuojamo langelio maksimalus atstumas. Be to,  $MP_1$  nurodo langelio „grūdėtumą“. Variogramos reikšmių vidurkis ir dispersija, atšvelgiant į reikšmes iki pirmo lokalaus maksimumo ( $MP_2, MP_3$ ), suteikia informacijos apie duomenų kintamumo dydį. Jie tiesiogiai susiję su homogeniškumu.  $MP_4$  parodo kaip greitai langelyje mažėja erdvinė koreliacija, atšvelgiant į reikšmes nuo vienetinio intervalo iki pirmo lokalaus maksimumo.

Antro variogramos funkcijos lokalaus maksimumo egzistavimas parodo, kad vaizdo langelyje yra tekstūros pasikartojimų. Tokiu atveju galima apskaičiuoti papildomus parametrus, kurie parodo funkcijos elgesį tarp pirmo ir antro lokalių maksimumų. Jeigu variograma yra monotoniškai didėjanti, parametrai nėra vertinami.

9. Atstumas tarp pirmų dviejų lokalių maksimumų:

$$*MMP_1 = h_{min_1} - h_{max_1}. \quad (2.18)$$

10. Duobės sritis:

$$MMP_2 = \frac{h(\gamma_{max_1} + 2(\sum_{i=max_1+1}^{max_2-1} \gamma_i) + \gamma_{max_2})}{(h_{max_2} - h_{max_1})(\gamma_{max_2} + \gamma_{max_1})}. \quad (2.19)$$

$MMP_1$  nurodo vaizdo struktūros taisyklingumo dydį.  $MMP_2$  suteikia informacijos apie įdubimo tarp dviejų maksimumų sumažėjimą ar padidėjimą ir įvertina duobės efektą, kuris tiesiogiai susijęs su vaizdo kontrastingumu.

### 2.3. Atraminių vektorių klasifikatorius

Atraminių vektorių sistemos (angl. *support vector machines, SVM*) yra vienas iš neparametrinių duomenų klavifikavimo metodų. SVM priklauso klasifikavimo algoritmų grupei, kurie naudoja apmokomąją imtį. SVM klasifikavimo esmė – atsitiktinio stebėjimo, kuris priklauso fiksuotam, bet nežinomam tikimybiniam skirstiniui, klaidingo klasifikavimo tikimybės minimizavimas. Be to, SVM metodo apmokymo metu visada pasiekiamas globalus minimumas. Pagrindinės šio klasifikatoriaus savybės <sup>[27]</sup>:

- Klasifikavimas neatsižvelgiant į duomenų aibės skirstinį;
- Klasifikatorius apmokomas sprendžiant iškilą optimizavimo uždavinį;
- Charakteristikų erdvėje sudaromas tiesinis klasifikatorius;
- Duomenų erdvėje gali būti sudaromas netiesinis klasifikatorius.

Bendru atveju, SVM yra binarinis klasifikatorius, kuris konstruojamas sudarant optimalią hiperplokštumą. Hiperplokštuma skiria dvi klases taip, kad atstumas nuo jos iki arčiausiai esančių apmokymo taškų iš kiekvienos klasės būtų maksimalus. Šis atstumas vadinamas hiperplokštumos parašte (angl. *margin*).

Turimoms stebėjimų poroms  $(\mathbf{x}_i, y_i)$ ,  $i = 1, \dots, l$ ,  $\mathbf{x}_i \in \mathbb{R}^n$ ,  $\mathbf{y} \in \{1, -1\}^l$ , atraminių vektorių sistemos su negriežta hiperplokštumos parašte (angl. *soft margin*) sprendinys optimizuojamas:

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l \xi_i; \quad (2.20)$$

kai

$$y_i(\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, \quad (2.21)$$

$$\xi_i > 0, \forall i.$$

čia funkcija  $\phi$  priskiria apmokomosios imties stebėjimus  $\mathbf{x}_i$  aukštesnės dimensijos erdvei (SVM sudaryta hiperplokštuma turės maksimalią paraštę šioje erdvėje),  $\mathbf{w}$  – ortogonalus hiperplokštumai vektorius,  $b$  - klasifikatoriaus poslinkis,  $C > 0$  yra baudos parametras,  $\xi_i$  - laisvieji kintamieji.

Šiam optimizavimo uždaviniui spręsti formuojamas dualus uždavinys, kurio sprendinys panaudojamas užrašant pradinio uždavinio sprendinį.

$$\min_{\alpha} \frac{1}{2} \alpha^T Q \alpha - \mathbf{e}^T \alpha; \quad (2.22)$$

kai

$$0 \leq \alpha_i \leq C, i = 1, 2, \dots, L, \quad (2.23)$$

$$\mathbf{y}^T \alpha = 0.$$

čia  $\mathbf{e} = (1, 1, \dots, 1) \in \mathbb{R}^L$ ,  $Q_{i,j} = y_i y_j \phi(\mathbf{x}_i) \phi(\mathbf{x}_j)$ .

Žinant dualaus uždavinio sprendinį randami atraminių vektorių sistemos klasifikatoriaus svoriai  $\mathbf{w}$ :

$$\mathbf{w} = \sum_{i=1}^L \alpha_i y_i \phi(\mathbf{x}_i). \quad (2.24)$$

Nuotolinio aptikimo vaizdų grupės dažnai būna persidengiančios parametrų atžvilgiu. Todėl tiesinis klasifikatorius keičiamas netiesiniu. Konstruojant netiesinę skiriamąją

plokštumą, SVM naudoja branduolio funkcijas  $K(\mathbf{x}_i, \mathbf{x}_j) \equiv \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$ . Toks atraminių vektorių sistemos išplėtimas leidžia transformuoti pradinius duomenis į didesnę dimensiją. Sakoma, kad tada sistema sudaroma panaudojant ‘branduolio apgaulę’ (angl. *kernel trick*).

Branduoliu vadinama išraiška:

$$K(\mathbf{x}, \mathbf{y}) = \phi(\mathbf{x})^T \phi(\mathbf{y}). \quad (2.25)$$

Pagal Marcerio teroremą, bet kuri pusiau teigiamai apibrėžta, simetrinė funkcija yra branduolys <sup>[23]</sup>.

Pagrindinės naudojamos branduolio funkcijos:

- Tiesinė funkcija

$$K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j; \quad (2.26)$$

- Polinominė funkcija

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma \mathbf{x}_i^T \mathbf{x}_j + r)^d, \gamma > 0; \quad (2.27)$$

- Radialinė bazinė funkcija (angl. *radial basis function, RBF*)

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2), \gamma > 0; \quad (2.28)$$

- Gauso radialinė bazinė funkcija

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2); \quad (2.29)$$

- Sigmoidinė (angl. *sigmoid*) funkcija

$$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^T \mathbf{x}_j + r); \quad (2.30)$$

čia  $\gamma, r$  ir  $d$  yra branduolių parametrai. Polinominės branduolio funkcijos dažniausiai yra naudojamos netiesiniam  $\mathbf{x}_i$  su  $d > 1$ . Be to, parametro  $d$  reikšmė sąlygoja skirtingą branduolio funkcijos veikimą, esant skirtingam kiekiui kintamųjų. Dažnai Gauso spindulinio pagrindo funkcijos naudojimas duoda geresnius klasifikavimo rezultatus nei paprastos spindulinio pagrindo funkcijos naudojimas <sup>[23]</sup>. Logistinė branduolio funkcija gali būti laikoma kaip tam tikros rūšies neuroninis tinklas.

### 2.3.1. Klasifikatoriaus parametrų parinkimas

SVM metodo taikymas yra glaudžiai susijęs su branduolio funkcijos bei jos parametrų parinkimu. Taip pat svarbi baudos parametro reikšmė. Konkretūs atraminiai vektoriai apibrėžia SVM skiriamąją plokštumą, todėl vieno bandymo apmokymas gali netiksliai atspindėti neklasifikuotų stebėjimų išsidėstymą. Kitaip tariant, SVM klasifikatorius su aukščiausiu apmokomosios imties klasifikavimo tikslumu nebūtinai sėkmingai klasifikuos nežinomų klasių stebėjimus.

Kryžminis patikrinimas yra įrankis, naudojamas nustatytant baudos ir branduolio parametrus, su kuriais klasifikatoriaus veikimas būtų kuo tikslesnis. Atliekant  $v$ -sluoksnių (angl. *v-folds*) kryžminį patikrinimą, pirmiausiai apmokomoji imtis yra padalinama į  $v$  lygių dalių. Viena po kitos atskiros dalys yra klasifikuojamos, panaudojant klasifikatorių, apmokytą naudojant likusias  $v - 1$  dalių. Taigi, kiekvienu atveju klasifikavimo klaidos, apskaičiuotos bandomosioms imtims, yra suvidurkinamos.  $V$ -sluoksnių kryžminio patikrinimo tikslumas yra teisingai klasifikuotų stebėjimų procentinis dydis.

Optimalūs klasifikatoriaus parametrai (branduolio bei baudos) parenkami tinkleline paieška (angl. *grid-search*). Kryžminiu patikrinimu yra išbandomos įvairios parametru kombinacijos, o optimaliais laikomi tie, su kuriais pasiektas didžiausias tikslumas. Norint supaprastinant parametru kombinacijų aibės dydį, parametru kombinacijos atnaujinamos sudarant vis tankesnę tinklelę. Rekomenduojama parametrus rinktis iš eksponentinio augimo sekų, vis patikslinant progresiją charakterizuojantį dydį <sup>[5]</sup>.

### 2.3.2. Daugiaklasis klasifikavimas atraminių vektorių klasifikatoriumi

SVM klasifikatorius yra skirtas binarinėms klasėms atskirti. Tačiau žemės paviršius gali būti skaidomas į kelias ar keliolika klasių. Daugiaklasio klasifikavimo atveju, SVM metodas naudojamas kaip viena klasė su kitomis arba viena klasė su viena <sup>[26]</sup>.

Viena klasė su kitomis atveju  $k$  klasėms yra konstruojama  $k$  klasifikatorių. Kiekvienas jų apmokomas atskirti kiekvieną klasę nuo visų kitų. Stebėjimas  $\mathbf{x}$  bus priskirtas klasei su didžiausia  $\mathbf{w}_i \phi(\mathbf{x}) + b_i$  reikšme. Įrodyta, kad toks klasifikavimas labiau tinkamas didelės aibės duomenų analizei <sup>[13]</sup>. Nors ir sudaromas didesnis kiekis klasifikatorių, tačiau klasifikavimo problema sprendžiama paprastesniais klasifikatoriais.

Viena klasė su viena metodas naudoja porinius palyginimus  $k$  klasėms. Taigi, kiekvienas klasifikatorius apmokomas tik dviems iš  $k$  klasių. Visos galimos viena su viena klasių kombinacijos yra įvertinamos apmokomajai imčiai, kurioje yra  $k$  klasių. Taigi iš viso bus sudaryta  $k(k - 1)/2$  klasifikatorių. Stebėjimai klasifikuojami pagal „balsavimo“ schemą – Priskiriami daugiausiai balsų surinkusiai klasei. Lygiaverčiu atveju, iš vienodą priskyrimų skaičių turinčių klasių pasirenkama atsitiktinė klasė arba priskiriama arčiausiai esančio stebėjimo klasė.

## 2.4. Klasifikuoto vaizdo apdorojimas

Klaidingas klasifikavimas, atsižvelgiant į vaizdo tekstūrą, dažniausiai susijęs su kraštu (angl. *edge*) tarp klasių kiekiu. Todėl dažnai atliekant vaizdų klasifikavimą pagal tekstūrą analizę yra stengiamasi įtraukti kuo mažiau kraštų. <sup>[10]</sup>

Analizuojamą vaizdą galima vadinti aukštos rezoliucijos, jeigu pikseliai atitinka mažesnę žemės plotą nei žemės paviršiaus objektai. Klasifikuojant kiekvieną aukštos rezoliucijos vaizdo pikselį, rezultatas dažnai pasižymi dideliu triukšmu. Šis klasifikavimo reiškinys pavadintas „druskos ir pipirų“ efektu <sup>[14]</sup>.

Tokius klasifikavimo netikslumus, blogą kraštų atpažinimą bei „druskos ir pipirų“ efektą, galima sumažinti glodinant klasifikuotą vaizdą. Vienas iš paprasčiausių glodinimo metodų –  $k$  artimiausių kaimynų <sup>[24]</sup>. Nustatytam artimiausių kaimynų skaičiui  $k$  glodinamo elemento reikšmei priskiriama aplinkos  $k$  elementų dažniausiai pasikartojanti reikšmė. Kaimynų artumas  $d$  vaizduose dažnai vertinamas Manhatano atstumo metrika:

$$d(x, y) = \sum_{i=1}^n |x_i - y_i|; \quad (2.31)$$

kur  $x_i, y_i$  – atitinkamų elementų  $x, y$  koordinatės.

## 2.5. Empirinis klasifikavimo tikslumo vertinimas

Objektų klasifikavimo uždavinyje svarbu įvertinti klasifikatoriaus tikslumą. Tam dažnai naudojamas bendras klasifikavimo tikslumas (angl. *overall accuracy of classification*), klasifikavimo klaidų matrica (angl. *confusion/error matrix*) bei Kapa statistika (angl. *Cohen's kappa coefficient*).

Bendras klasifikavimo tikslumas parodo, kokia viso vaizdo dalis yra teisingai suklasifikuota. Tikslumo įvertinys:

$$\hat{P}_t = \frac{n_t}{N}; \quad (2.32)$$

čia  $n_t$  yra teisingai suklasifikuotų objektų skaičius,  $N$  - visų klasifikuotų objektų skaičius.

Klasifikavimo klaidų matrica sudaroma norint įvertinti kiekvienos klasės klasifikavimo tikslumą. Tokioje matricoje kiekvienas stulpelis žymi klasifikuotų elementų, priskirtų tam tikrai klasei, skaičių, o kiekviena eilutė žymi elementų, priklausančių atitinkamai klasei, skaičių. Iš matricos elementų galima apskaičiuoti klasifikavimo klaidų tikimybes. Šios tikimybės dažnai vertinamos pagal turimus duomenis, nes analitinė išraiška yra sunkiai gaunama.



Kapa koeficientas taikomas rezultatų tarpusavio suderinamumui nustatyti, jis apskaičiuojamas:

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} x_{+i})}; \quad (2.33)$$

čia  $r$  yra klaidų matricos eilučių ir stulpelių numeris,  $N$  – klasifikuotų taškų skaičius,  $x_{ii}$  – teisingai priskirtų  $i$  klasei taškų skaičius,  $x_{i+}$  - bendras  $i$  klasės klasifikuotų taškų skaičius,  $x_{+i}$  - bendras  $i$  klasei priskirtų taškų skaičius.

### 3. NUOTOLINIO APTIKIMO VAIZDO KLASIFIKAVIMAS

Šiame skyriuje pateikiami vaizdo erdviųjų parametrų įtakos nuotolinio aptikimo vaizdo klasifikavimui tyrimo rezultatai. Analizė atliekama šiais etapais:

- Variogramos ir jos parametrų skaičiavimas tam tikro dydžio vaizdo langeliams;
- Atraminių vektorių sistemos branduolio funkcijos parinkimas, parametrų optimizavimas;
- Klasifikatoriaus apmokymas ir bandomosios imties klasifikavimo tikslumo įvertinimas.


#### 3.1. Tiriamas nuotolinio aptikimo vaizdas

Tyrimo naudojamos Kauno miesto palydovinės RGB modelio nuotraukos, kuriose vienas pikselis atitinka 1 metrą fizinio paviršiaus. Kadangi augmeniją geriausiai identifikuoja raudonos spalvos spektras, todėl parametrai apskaičiuojami iš vaizdų raudono spektro juostos reikšmių.


Šiam tyrimui sudaromos 6 tikslinės klasės: miškas, vanduo, dirvožemis, pavieniai medžiai, pieva ir bitumo danga. Šių klasių pavyzdžiai pateikiami 3.1-3.6 paveiksluose. Vertinant ekspertiškai, išsiskiriančią tekstūrą turi miškas, dirvožemis bei pavieniai medžiai, tuo tarpu vandens, pievos ir bitumo dangos tekstūros viena nuo kitos beveik nesiskiria.



**3.1 pav.** Miško klasės (1) bandomasis vaizdas




**3.2 pav.** Vandens klasės (2) bandomasis vaizdas



**3.3 pav.** Dirvožemio klasės (3) bandomasis vaizdas



**3.4 pav.** Pavienių medžių klasės (4) bandomasis vaizdas



**3.5 pav.** Pievos klasės (5) bandomasis vaizdas




**3.6 pav.** Bitumo dangos klasės (6) bandomieji vaizdai

Klasifikatorius apmokomas naudojant imties raudonos spalvos intensyvumo statistikas bei variogramą aprašančius parametrus (1.3.1. skyrelis). Šie parametrai vertinami  $13 \times 13$  pikselių dydžio slenkančiam langeliui. Laikoma, kad gauti parametrai charakterizuoja centrinį langelio pikselį. Be to, pagal slenkančio langelio dydį yra vertinama šešių reikšmių variograma. Mokymo imtį sudaro 30% (2000) atsitiktinių kiekvienos klasės elementų, likę elementai naudojami vertinant klasifikavimo tikslumą. Taip pat atliekamas klasifikavimas vaizdai, kuriame fiksuotos kelios klasės (3.7 pav.), norint ištirti klasifikatoriaus veikimą mišraus vaizdo atveju. Tokiam vaizdai klasės priskiriamos ne automatiniu būdu (3.8 pav.). Kadangi galima nevienareikšmiška interpretacija, todėl tyrime mišraus vaizdo klasifikavimo tikslumas nebus vertinamas.




**3.7 pav.** Mišrus vaizdas




**3.8 pav.** Mišraus vaizdo klasės

Prieš atliekant atraminių vektorių sistemų klasifikavimą svarbu standartizuoti duomenis aprašančias reikšmes. Pagrindinis standartizavimo tikslas yra suvienodinti kintamųjų matavimo skales. Taip pat, kadangi branduolio reikšmės priklauso nuo vidinių kintamųjų sandaugų, standartizavimas panaikina itin didelių sandaugos rezultatų atsiradimą. Klasifikavimui naudojamų parametrų standartizuotų reikšmių vidurkis lygus 0, standartinis nuokrypis –1.


$13 \times 13$  dydžio langeliuose apskaičiuotos skirtingų klasių atsitiktinės variogramos vaizduojamos 3.9-3.14 paveiksluose. Variogramos, priklausančios skirtingoms klasėms, pasižymi tam tikromis tendencijomis. Miško klasės variogramos (3.9 pav.) išsiskiria dideliu spektro kintamumu tarp esant dideliame elementų erdviniam atskyrimui. Dideliu spektro kintamumu taip pat išsiskiria pavienių medžių klasė (3.12 pav.), tačiau čia, dauguma variogramos funkcijų pasiekę lokalų maksimumą toliau nebeauga. Mažu spektriniu kintamumu pasižymi vandens (3.10 pav.) bei pievos klasės (3.13 pav.). Dauguma variogramų, priklausančių dirvožemio (3.11 pav.) ir bitumo (3.14 pav.) yra žemo spektrinio kintamumo. Šių klasių variogramos pasižymi nepastovumu.




**3.9 pav.** Miško klasės atsitiktinės variogramos




**3.10 pav.** Vandens klasės atsitiktinės variogramos




**3.11 pav.** Dirvožemio klasės atsitiktinės variogramos



**3.12 pav.** Pavienių medžių klasės atsitiktinės variogramos



**3.13 pav.** Pievos klasės atsitiktinės variogramos




**3.14 pav.** Bitumo klasės atsitiktinės variogramos

### 3.2. Klasifikavimas pagal variogramos modelio koeficientus

Empirinė variograma gali būti modeliuojama tam tikromis kreivėmis. 3.9-3.14 paveiksluose dauguma variogramų yra tarsi apribotos tam tikros variacijos reikšmės. Todėl šiame tyrime funkcijoms yra taikomas sferinis modelis, kur tariama, kad funkcija, pasiekusi savo slenktį, nebedidėja.

Variogramų sferinių modelių koeficientai gaunami mažiausių kvadratų metodu su svoriais, kur svoriai nustatomi pagal 1.8 išraišką. Gautų koeficientų išsibarstymas matomas 3.15 paveiksle (čia spalvų ir klasių atitikmenys: mėlyna - miškas, žalia - vanduo, raudona - dirvožemis, žydra – pavieniai medžiai, rožinė - pieva, geltona – bitumo danga). Pastebima, kad miško ir pavienių medžių koeficientai labiausiai susimaišę ir, palyginus su kitais koeficientais, jų slenksčio atstumai įgyja didesnes reikšmes. Taip pat pastebima, kad pievos ir vandens klasių variogramos modelių slenksčio atstumas itin mažas – šių klasių langeliuose nėra struktūrų pasikartojamumo.




**3.15 pav.** Langelių variogramų modelių slenksčio ir slenksčio atstumo sklaidos diagrama

Klasifikavimo uždavinys sprendžiamas atraminių vektorių sistemos modeliais – palyginami modeliai su tiesiniu branduoliu bei radialinės bazinės funkcijos branduoliu. Šešioms klasėms atskirti atraminių vektorių sistemai taikoma viena klasė su visomis metodika, t.y. konstruojami šeši klasifikatoriai, kur kiekvienas jų apmokomas atskirti kiekvieną klasę nuo

visų kitų. Klasifikatoriaus parametrai optimizuojami atliekant tinklelinę paiešką su parametru seka  $C = 2^{-3}, 2^{-1}, 2^1, 2^3, 2^5, 2^7$ . Radialinės bazinės branduolio funkcijos atveju tinklelinė paieška vykdoma papildomai su parametru seka ir  $\gamma = 2^{-3}, 2^{-1}, 2^1, 2^3$ . Tai pat, kiekvienai iš sekų porų atliekamas dešimties sluoksnių kryžminis patikrinimas.

Klasifikatoriaus su radialinės bazinės funkcijos branduoliu tikslumas su atitinkama parametru pora vaizduojama 3.16 paveiksle. Vidutinis apmokymo tikslumas su šiais parametrais, naudojant 10 sluoksnių kryžminį patikrinimą – 66%. Matome, kad nuo tam tikros reikšmės didinant baudos parametru  $C$ , klasifikatoriaus tikslumas nebeagerėja.



**3.16 pav.** SVM klasifikatorių optimalių parametru tinklelinė paieška, klasifikavimas pagal variogramos modelio koeficientus

Lyginamų skirtingų branduolių klasifikatorių modeliai su optimaliais parametrais aprašomi 3.1 lentelėje. Radialinės bazinės funkcijos branduolio atveju optimalios atsikiriamosios hiperplokštumos yra apibrėžiamos dideliu kiekiu atraminių vektorių. Taip yra dėl didelės optimalaus klasifikavimo parametro  $C$  reikšmės. Tiesinio branduolio atveju, klasifikatoriams suteikiamas didesnis poslinkis  $b$ . Toliau atliekamas klasifikavimas naudojant radialinės bazinės funkcijos branduolį.

Skirtingų klasių klasifikavimo tikslumai pateikiami 3.2 lentelėje. Bendras testuojamos imties tikslumas – 67.42%,  $\kappa = 0.67$ . Matome, kad geriausiai klasifikuojami vandens bei pievos pikseliai, nors variogramų modelių koeficientai turėtų gerai diskriminuoti miško ar pavienių medžių klasių pikselius.

3.1 lentelė. Sudaryti atraminių vektorių sistemų klasifikavimo modeliai

Branduolys	Optimalūs parametrai	Klasifikatorių atraminių vektorių kiekis	Klasifikatorių poslinkis, $b$
RBF	$C = 8, \gamma = 0.125$	1469, 1383, 1548, 1654, 1087, 1301	0.34, -1.93, -0.38, -0.89, -0.77, -1.38
Tiesinis	$C = 10$	118, 7, 1788, 1252, 499, 590	8, -2.38, -2.23, -2.83, -16.55, -8.96

3.2 lentelė. Klasių bandomųjų imčių klasifikavimo pagal variogramos modelio koeficientus tikslumai, klaidingo klasifikavimo įverčiai

Klasifikuojamas vaizdas	Tikslumas	Klaidingai priskirtų klasės elementų kiekis	Klaidingai priskirtų klasei elementų kiekis
Miškas	68.87%	467	555
Vanduo	78%	330	595
Dirvožemis	60.93%	586	422
Pavieniai medžiai	61.73%	574	584
Pieva	87.93%	181	260
Bitumas	47.07%	784	526

3.3 lentelėje pateikiama klasifikavimo klaidų matrica. Iš čia: 28% miško elementų priskiriama pavieniams medžiams, ir atvirkščiai, 31% pavienių medžių elementų priskiriama miško klasei. Taip pat 13% vandens pikselių suklasifikuota kaip pieva, dirvožemio 11% pikselių – kaip vanduo, 18% - kaip bitumo danga, po 20% bitumo dangos elementų priskiriama vandeniui ir dirvožemiui. Miško ir pavienių medžių klasių tekstūra skiriasi gana akivaizdžiai, tačiau šios klasės yra maišomos klasifikarių su analizuojamais parametrais. Taip pat, atsižvelgiant į nedidelius klasifikavimo tikslumo įverčius, šie vertinami kaip blogai diskriminuojantys vaizdą pagal jo tekstūrą.

3.3 lentelė. Testavimo imties klasifikavimo pagal variogramos modelio koeficientus klaidų matrica


		Suklasifikuota klasė					
		1	2	3	4	5	6
Reali klasė	1	1033	0	51	416	0	0
	2	0	1170	14	0	189	127
	3	88	169	914	37	19	273
	4	466	0	51	926	0	57
	5	0	122	0	0	1319	59
	6	1	304	306	131	52	706



### 3.3. Klasifikavimas pagal variogramos funkcijos parametrus

Atliekamas klasifikavimas pagal šiuos variogramos bendruosius bei pirmo maksimumo parametrus:  $BP_1, BP_2, BP_3, MP_2, MP_3, MP_4$ .  $MP_1$  nenaudojamas, nes jis įgyja sveikas reikšmes nuo vienoto iki šešto. Taip pat, kadangi tik nedaugelis variogramų pasižymi antro lokalaus maksimumo egzistavimu, todėl antro maksimumo parametrai neįtraukiami.

Variogramas aprašančių parametų  $BP_3, MP_2, MP_4$  išsibarstymas skirtingoms klasėms vaizduojamas 3.17 paveiksle. Iš čia, aiškiai išsiskiriančių klasių pagal parametų reikšmės nepastebima, klasių taškų išsibarstymai panašūs į variogramos modelių koeficientų sklaidos diagramos išsibarstymą (3.15 pav.), kur tarpusavyje maišosi miško ir pavienių medžių taškų parametrai, dirvožemio ir bitumo dangos, bei vandens ir pievos elementų parametrai.




3.17 pav. Variogramos funkcijų  $BP_3, MP_2, MP_4$  parametų sklaidos diagrama

Kadangi norima palyginti tekstūrą charakterizuojančius parametrus, toliau naudojamas atraminių vektorių klasifikatorius su radialinės bazinės funkcijos branduoliu. Klasifikatoriaus parametrai optimizavimas atliekamas su identiškais parametų sekomis (3.18 pav).



Parametrai klasifikatorių apmokymui:  $C = 16$  ir  $\gamma = 2$ . Vidutinis apmokymo tikslumas su šiais parametrais, naudojant 10 skuoksnių kryžminį patikrinimą – 80%.



**3.18 pav.** SVM klasifikatorių optimalių parametų tinklelinė paieška, klasifikavimas pagal BP ir MP

Bendras testavimo imties klasifikavimo tikslumas – 78.27%, kapa statistika  $\kappa = -0.78$ . Skirtingų klasių vaizdų tikslumai pateikiami 3.4 lentelėje. Mažiausias klasifikavimo gaunamas dirvožemio bei bitumo klasėms. Tekstūra išsiskiriančios klasės, miškas ir pavieniai medžiai, klasifikuojami pakankamai gerai, lyginant su klasifikavimu pagal variogramos modelio koeficientus. Taip pat geriau išsikiriamos kitos, tekstūra nepasižyminčios klasės: vanduo ir pieva.

**3.4 lentelė.** Klasių bandomųjų imčių klasifikavimo pagal BP ir MP variogramos parametrus tikslumai, klaidingo klasifikavimo įverčiai


Klasifikuojamas vaizdas	Tikslumas	Klaidingai priskirtų klasės elementų kiekis	Klaidingai priskirtų klasei elementų kiekis
Miškas (1)	81.67%	275	218
Vanduo (2)	78.27%	326	345
Dirvožemis (3)	64.93%	526	417
Pavieniai medžiai (4)	83.07%	254	302
Pieva (5)	90.33%	145	281
Bitumas (6)	71.33%	430	393

Iš klasifikavimo klaidų matricos (3.5 lentelė) matoma, kad daugiausiai tarpusavyje yra maišomos miško bei pavienių medžių klasės: 13% miško elementų priskiriama pavienių medžių klasei, 11% pavienių medžių element priskiriama miškui. Taip pat maišoma vandens, dirvožemio, pievos ir bitumo dangos klasės: 4% vandens elementų suklasifikuota dirvožemiui, 13% – pievai, 11% dirvožemio elementų priskirta vandeniui, 16%– bitumui, 6% pievos elementų priskirta vandeniui, 15% bitumo dangos priskirta dirvožemiui.


**3.5 lentelė. Testavimo imties klasifikavimo pagal BP ir MP variogramos parametrus klaidų matrica**

		Suklasifikuota klasė					
		1	2	3	4	5	6
Reali klasė	1	1225	0	81	192	0	2
	2	0	1174	59	0	208	59
	3	56	169	974	40	25	236
	4	160	0	37	1246	0	57
	5	0	97	9	0	1355	39
	6	2	79	231	70	48	1070


Klasifikuotas mišrus vaizdas pateikiamas 3.19 paveiksle (čia klasių ir spalvų saryšis: žalia – miškas, mėlyna - vanduo, oranžinė – dirvožemis, raudona – pavieniai medžiai, žydra – pieva, tamsiai mėlyna – bitumo danga). Gaunamas gana neaiškus ir painus žemės paviršių žemėlapis, kur matomas aiškus klasių susimaišymas.



**3.19 pav.** Klasifikuotas mišrus vaizdas, klasifikuojama pagal bendruosius ir pirmo maksimumo variogramos parametrus



**3.20 pav.** Langelių spektro vidurkio ir standartinio nuokrypio sklaidos diagrama



**3.21 pav.** SVM klasifikatorių optimalių parametų tinklelinė paieška, klasifikavimas pagal statistikas, BP ir MP parametrus

Parametrai papildomi pikselio aplinkos spektro statistikomis: vidurkiu ir standartiniu nuokrypiu. Šių statistikų sklaidos diagramoje (3.20 pav.) matomos aiškiai atsiskiriančios klasės pagal parametų reikšmes. Daugiau tarpusavyje maišoma tik dirvožemio ir bitumo dangos

elementai. Kadangi variogramą aprašantys parametrai teisingai neatskiria panašios tekstūros, tačiau skirtingo spektrinio intensyvumo klasių, tikimasi, kad šių parametru įtraukimas pagerins klasių atskiriamumą. Klasifikavimui taip pat paliekami pagrindiniai variogramos parametrai:  $BP_3, MP_2, MP_4$ .

Optimalūs atraminių vektorių sistemos parametrai:  $C = 128$  ir  $\gamma = 2$  (3.21 pav.). Vidutinis apmokymo tikslumas su šiais parametrais, naudojant 10 skuoksnių kryžminį patikrinimą – 97.5%.

Bendras testavimo imties klasifikavimo tikslumas – 94.53%, kapa statistika  $\kappa = 0.95$ . Skirtingų klasių vaizdų tikslumai ženkliai pagerėjo (3.6 lentelė).

**3.6 lentelė. Klasių bandomųjų imčių klasifikavimo pagal statistikas, BP ir MP parametrus tikslumai, klaidingo klasifikavimo įverčiai**

Klasifikuojamas vaizdas	Tikslumas	Klaidingai priskirtų klasės elementų kiekis	Klaidingai priskirtų klasei elementų kiekis
Miškas	99.13%	13	2
Vanduo	100%	0	0
Dirvožemis	98.73%	19	458
Pavieniai medžiai	99.87%	2	13
Pieva	100%	0	0
Bitumas	69.47%	458	19


Iš klasifikavimo klaidų matricos (3.7) matomas tik bitumo dangos klasės neatskyrimas: 30% šios klasės elementų priskiriama dirvožemiui.

**3.7 lentelė. Testavimo imties klasifikavimo pagal statistikas, BP ir MP parametrus, klaidų matrica**

		Suklasifikuota klasė					
		1	2	3	4	5	6
Reali klasė	1	1487	0	0	13	0	0
	2	0	1500	0	0	0	0
	3	0	0	1481	0	0	19
	4	2	0	0	1498	0	0
	5	0	0	0	0	1500	0
	6	0	0	458	0	0	1042

Suklasifikuotas mišrus vaizdas pateikiamas 3.22 paveiksle. Šio vaizdo klasifikavimo klaidų matrica pateikiama 3.7 lentelėje. Matricos reikšmės yra tik grubūs klaidingo

klasifikavimo vertinimai. Tačiau itin išsiskiria pievos klasės neatskiriamumas: 17% priskirta miško, 12% - vandens, 10% - dirvožemio, 19% - pavienių medžių klasėms.



**3.22 pav.** Klasifikuotas pagal pagrindinius BP ir MP, ir spektro statistikas mišrus vaizdas

**3.8 lentelė.** Mišraus vaizdo klasifikavimo pagal statistikas, BP ir MP parametrus klaidų matrica

		Suklasifikuota klasė					
		1	2	3	4	5	6
Reali klasė	1	28183	3685	386	5338	60	0
	2	3603	11584	1	412	983	10
	3	347	535	2422	813	13510	352
	4	821	27	187	1774	246	3
	5	19262	14296	12062	22625	40787	5319
	6	6389	0	4047	4450	322	50

### 3.4. Rezultatų aptarimas

Darbe buvo nagrinėjama multispektrinį nuotolinio aptikimo vaizdą aprašančių erdvinių charakteristikų įtaka tų vaizdų klasifikavimui. Tyrimas atliktas naudojant aukštos rezoliucijos Kauno miesto palydovines nuotraukas.

Pirmiausiai buvo analizuojamos variogramos sferinio modelio koeficientų – slenksčio ir slenksčio atstumo, kaip tekstūros parametrų, skirtingų klasių atskiriamumo galimybes. Tokiu atveju sprendžiant koeficientų optimizavimo uždavinį variograma įgauna analizinę išraišką.

Įvairioje literatūroje diskutuojama, ar variogramos modeliavimas yra efektyvus metodas norint aprašyti vaizdo tekstūrą. Pritaikius atraminių vektorių sistemos klasifikatorių su radialinės bazinės funkcijos branduoliu, bandomajai imčiai nustatytas 67.42% klasifikavimo tikslumas. Geriausiai klasifikuojami vandens ir pievos klasių pikseliai, nors variogramų modelių koeficientai turėtų gerai diskriminuoti tekstūra išsiskiriančias klases - miško ar pavienių medžių klasių elementus. Kadangi visoms variogramoms buvo taikomas vienas modelis, negalima pilnai spręsti apie sėkmingą modeliavimo įgyvendinimą – ateityje galima bandyti skirtingoms klasėms pritaikyti įvairius variogramos modelius.

Toliau buvo tiriama variogramos funkciją aprašančių išvestinių parametru įtaka vaizdų klasifikavimui. Gautas bendras testavimo imties klasifikavimo tikslumas – 78.27%. Šiuo atveju daugiausiai tarpusavyje yra maišomos miško bei pavienių medžių klasės, taip pat dirvožemio ir bitumo dangos, pievos ir vandens klasės. Analizuojami parametrai yra nesudėtingai apskaičiuojami iš variogramos reikšmių. Tam tikra prasme jie tuo pačiu atspindi ir variogramos slenkstį, nes daugumos jų apskaičiavimui naudojamas funkcijos maksimumas.

Kadangi variogramą aprašantys parametrai teisingai neatskiria panašios tekstūros, tačiau skirtingo spektrinio intensyvumo klasių, nuspręsta charakterizuojančius parametrus papildyti elemento aplinkos spektrinio intensyvumo statistikomis – vidurkiu ir standartiniu nuokrypiu. Klasifikavimo tikslumas žymiai pagerėjo - iki 94.53%. Klasifikuojant pagal papildytą parametru aibę sunkiau atskiriama bitumo dangos klasė. Galima teigti, kad spektro intensyvumo ir tekstūros parametru sujungimas tekstūra pasižyminčių vaizdų klasifikavime teikia naudą.

Klasifikuotų mišrių vaizdai yra gana neaiškūs žemės paviršiaus teminiai žemėlapiai. Tam tikra prasme šis prastas mišrių vaizdų klasifikavimas susijęs ir su kraštų tarp klasių neatskiriamumu. Taip gali būti dėl dominuojančių klasių egzistavimo klasifikavimui naudojamuose 13×13 dydžio langeliuose. Pavyzdžiui, abejais atvejais sunkiai atpažystama bitumo danga. Gali būti, kad šios klasės betarpiško išsidėstymo plotas yra per mažas analizuojamam langeliui, todėl šios klasės elementai yra priskiriami pagal aplinkos elementu parametrus. Tačiau per ne lyg mažame langely nebūtų aptinkami vaizdo pasikartojamumai.

Visais atvejais buvo taikomas atraminių vektorių klasifikatorius, su „minkštomis“ skiriančiomis hiperplokštumos paraštėmis – sudaryti modeliai su laisvais elementais (vektoriais), kurie patenka į hiperplokštumos paraštę. Taikant šį metodą darbe susiduriama su trūkumu – klasifikatoriaus parametrai yra sunkiai interpretuojami.

## 4 NUOTOLINIO APTIKIMO VAIZDO KLASIFIKAVIMUI TAIKOMA PROGRAMINĖ ĮRANGA

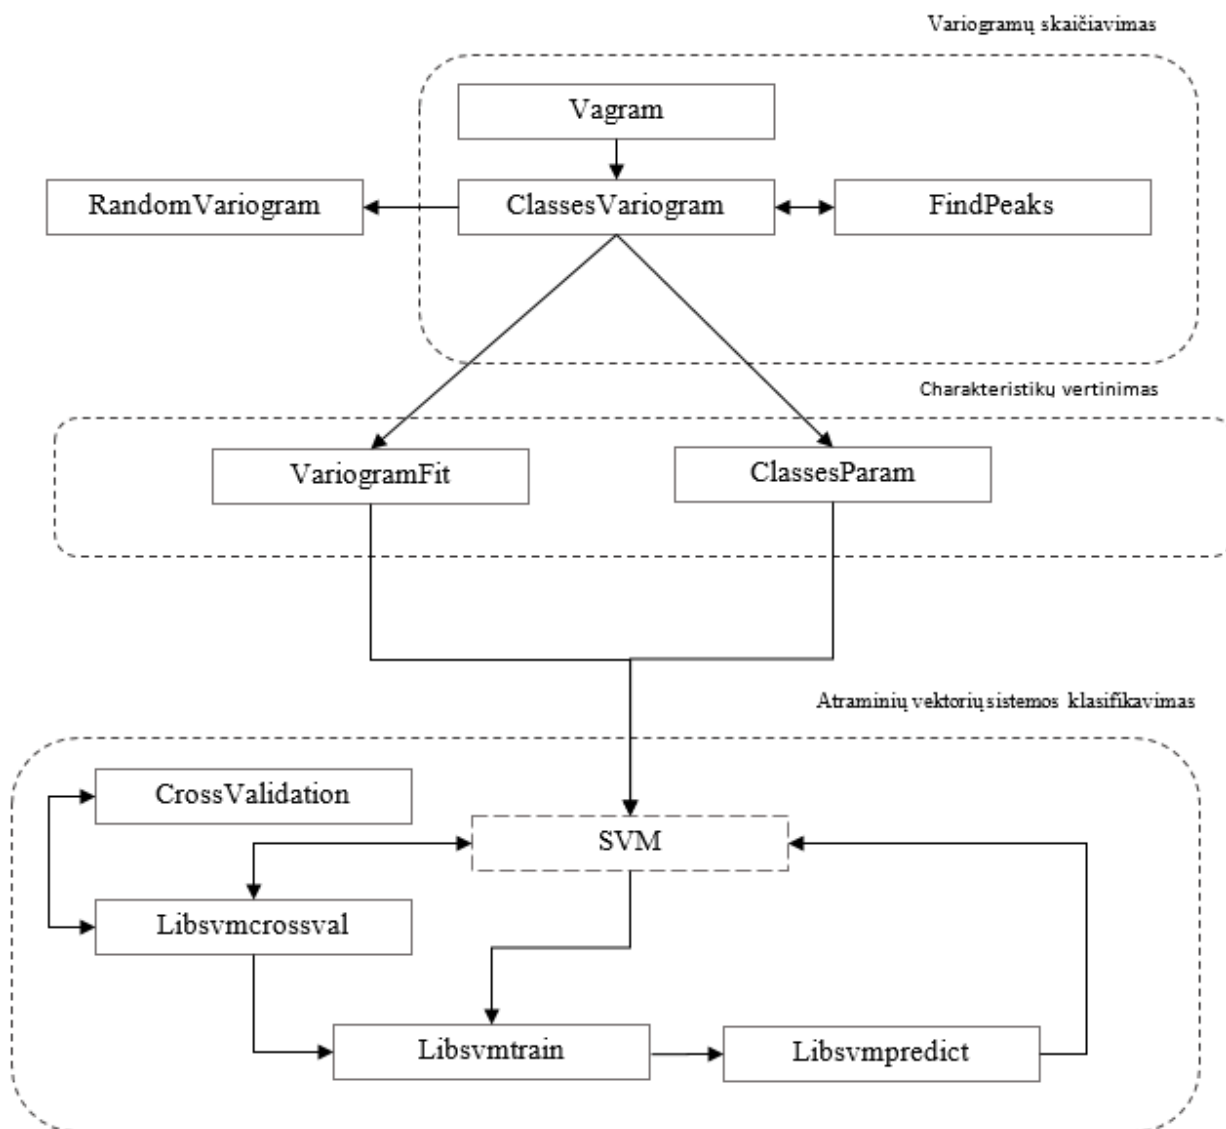
Tyrimė naudojami metodai realizuoti Matlab programine įranga. Programoje naudojamos standartinės funkcijos bei specifinių paketų (Bioinformatics, Statistics, Statistics and Machine Learning, Image Processing) funkcijos. Variogramų modeliavimui ir modelių koeficientų optimizavimui naudojama MathWorks (#25948) funkcija. Atraminių vektorių sistemos klasifikavimui naudojamos LIBSVM bibliotekos funkcijos <sup>[5]</sup>. Visos naudojamos funkcijos ir jų paskirtis aprašoma 4.1 lentelėje.

**4.1 lentelė. Programoje realizuojamos funkcijos ir jų paskirtis**

Funkcijos pavadinimas	Paskirtis
ClassesParam( <i>paramdata,r</i> )	Išvestinių variogramos <i>r</i> reikšmių ( <i>paramdata</i> ) skaičiavimas
ClassesVariogram( <i>P,band,r,label</i> )	Apskaičiuoja <i>r</i> variogramos reikšmių, bei jų lokalius maksimumus (jeigu jų yra) paveiksluko <i>P</i> nurodytam spektro sluoksniui ( <i>band</i> ). Apskaičiuotos reikšmės identifikuojamos klasės pavadinimu ( <i>label</i> )
FindPeaks( <i>data,l</i> )	Lokalių maksimumų paieška <i>data</i> stebėjimams.
SVMParmSelection( <i>lab,dat,fold,par1,par2</i> )	Atliekamas optimalių parametų tinklinė paieška duomenims <i>dat</i> su klasių identifikatoriais <i>lab</i> . Parametrai vertinami atliekant skaičių <i>fold</i> sluoksnių kryžminį patikrinimą. <i>par1</i> ir <i>par2</i> nurodomos parametų, atitinkamai <i>C</i> ir $\gamma$ , sekos.
Vagram( <i>P,r</i> )	<i>P</i> vaizdo <i>r</i> variogramos reikšmių skaičiavimas kiekvienam elementui
Crossvalidation( <i>y, nfold</i> )	Mokymo ir testavimo <i>nfold</i> dalių sudarymas <i>y</i> stebėjimų kryžminiam patikrinimui.
Libsvmcrossval( <i>y, X, opts, nfold, indices</i> )	Atlieka <i>nfold</i> skaičių sluoksnių kryžminį patikrinimą <i>X</i> parametrams su <i>y</i> klasėmis. Atraminių vektorių sistema naudoja <i>opts</i> parametrus. Apmokymo ir testavimo stebėjimai gali būti nurodomi su <i>indices</i> .
Libsvmpredict( <i>y, X, mdl</i> )	<i>X</i> stebėjimų daugiaklasis klasifikavimas pagal apmokytą atraminių vektorių modelio struktūrą <i>mdl</i> . Tikslumas vertinamas pagal originalias stebėjimų klases <i>y</i> .
Libsvmtrain( <i>y, X, opts</i> )	Atraminių vektorių sistemos klasifikatoriaus apmokymas su parametrais <i>opts</i> . Apmokomoji imtis - <i>X</i> su klasių identifikatoriais <i>y</i> .
Efektyvumas	Mišraus vaizdo lasifikavimo efektyvumo vertinimas
KnnSmooth	Elementų glodinimas pagal dažniausiai pasikartojančią reikšmę apibrėžto dydžio langelyje.
RandomVariogram( <i>n,lags, data, lab</i> )	<i>n</i> atsitiktinių variogramų vaizdavimas, <i>data</i> - variogramos <i>lags</i> reikšmių.
Variogramfit( <i>h,gammaexp,...</i> )	Empirinės variogramos modeliavimas, <i>gammaexp</i> variogramos reikšmės apskaičiuotos <i>h</i> intervalams.

### 4.3 PROGRAMOS TAIKYMO APRAŠYMAS

Realizuotų funkcijų naudojimo eiliškumas pagal tyrimo metu atliekamą modelį vaizduojamas 4.1 paveiksle.



4.1 pav. Funkcijų taikymo eiliškumas



## IŠVADOS

1. Išanalizuotos nuotolinio aptikimo vaizdų klasifikavimo galimybės. Klasifikatoriaus parinkimas nėra esminis klasifikuojant tokius vaizdus – efektyvesniam vaizdų interpretavimui daugiau įtakos turi parametų vektoriaus sudarymas. Multispektrinio vaizdo atveju svarbu klasifikavimo parametrus papildyti vaizdo erdvinį kintamumą charakterizuojančiais parametrais. Klasifikuojant hiperspektrinį vaizdą, svarbu išskirti daugiausiai informacijos suteikiančius spektro parametrus.
2. Panaudojus geostatistikos, daugiamatės statistikos bei optimizavimo metodus, sudaryti nuotolinio aptikimo vaizdų klasifikavimo modeliai. Modeliuose vertinama tiek vaizdo sprektrinis intensyvumas, tiek jo tekstūra.
3. Išanalizuotas variogramos pritaikymas vaizdo tekstūros atpažinimui. Pasiūlyta vaizdo tekstūrą aprašyti variogramos modelio koeficientais arba variogramos išvestiniais parametrais. Klasifikatoriaus sudarymui naudojamas atraminių vektorių sistemų modelis. Atlikus palyginimus nustatyta, kad tiksliau ir paprasčiau tekstūra aprašoma išvestiniais parametrais. Palyginus įvairių spektrinių ir tekstūros parametų bei jų kombinacijų taikymo efektyvumą klasifikuojant nuotolinio aptikimo vaizdus, nustatyta, kad efektyviausias yra skirtintingą informaciją aprašančių parametų sujungimas.

## LITERATŪRA

1. Atkinson P.M., Leirs P. Geostatistical classification for remote sensing: an introduction. *Computers and Geosciences*, 2000, vol. 26, p. 361-371.
2. Balaguer, A. Ruiz L., Hermosilla T. Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification. *Computers and Geosciences*, 2010, vol. 36, no. 2, p. 231–240.
3. Carr, J.R. Spectral and textural classification of single and multiple band digital images. In *Computers and Geosciences*, 1996, vol. 22, no. 8, p. 849–865.
4. Carr J.R, Miranda, F. De. The semivariogram in comparison to the co-occurrence matrix for classification of image texture. *IEEE Transactions on Geoscience and Remote Sensing*, 1998, vol. 36, no. 6, p. 1945–1952.
5. Chin-Wei H., Chin-Chusng C.. A Practical Guide to Support Vector Classification. *BJU international*, 2008, vol. 101, no. 1, p. 1396–400.
6. Cressie, N. Fitting variogram models by weighted least squares. *Journal of the International Association for Mathematical Geology*, 1985. Vol. 17, no. 5, p. 563–586.
7. Debes, C., Merentitis A., Heremans R., Jurgen H., Frangiadakis N., Van Kasteren T., Liao W. et al. Hyperspectral and LiDAR data fusion: Outcome of the 2013 GRSS data fusion contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, vol. 7, no. 6, p. 2405–2418.
8. Durrieu, M. Image feature extraction from the experimental semivariogram and its application to texture classification, 2007.
9. Eastman, J.R. IDRISI Guide to GIS and Image Processing Volume I. Idrisi Production, Clark University, 2001, 316p.
10. Ferro C.J.S., Warner T.A. Scale and texture in digital image classification. *Photogrammetric Engineering & Remote Sensing*, 2002, vol. 68, p. 51–63.
11. Habib, T. Inglada J., Mercier G., Chanussot J. Support Vector Reduction in SVM Algorithm for Abrupt Change Detection in Remote Sensing. *IEEE Geoscience and remote sensing letters*, 2009. Vol. 6, no. 3, p. 606–610.
12. Higginson, C.A. Automated Feature Vectors, and Discrimination Criteria. *Computers & Geosciences*, 1996, vol. 22, no. 1.
13. Hsu C.W., Lin C.J. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*, 2002, vol. 13, no. 2, p. 415–425.
14. Kettig R.L., Landgrebe, D.A. Classification of multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Geoscience Electronics*, 1975, vol. 14, no. 1, p. 19–26.

15. Lippitt, C.D., Rogan J., Li Z., Eastman R., Jones T.G. Mapping selective logging in mixed deciduous forest: a comparison of machine learning algorithms. *Photogrammetric Engineering & Remote Sensing*, 2008, vol. 74, no. 10, p. 1201–1211.
16. Mantero P., Moser G., Serpico S.B. Partially Supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, vol. 43, no. 3, p. 559–570.
17. Mather, P., Magaly, K. *Computer Processing of Remotely-Sensed Images: An Introduction*, 4th ed. Hoboken: John Wiley & Sons, 2010, 460 p.
18. Melgani F., Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, vol. 42, no. 8, p. 1778–1790.
19. Oliver M., Webster R., Gerrard J.. Geostatistics in physical geogrpahy. Part I: theory. *Transactions of the Institute of British Geographers*, 1989, vol. 14, no. 3, p. 259–269.
20. Pal N.R., Pal S.K. A review on image egmentation techniques. *Pattern Recognition*, 1993, vol. 26, no. 9, p. 1277–1294.
21. Pouteau, R. Collin A., Stoll B. *A Comparison of Machine Learning Algorithms for Classification of Tropical Ecosystems Observed by Multiple Sensors at Multiple Scales*, 2010.
22. Schowengerdt, R.A. *Remote sensing: models and methods for image processing*, 2nd ed. Saint Louis: Academic Press, 1997, 585 p.
23. Shawe-Taylor, J., Cristianini, N. *Kernel Methods for Pattern Analysis*. Cambridge University Press, 2004, 478 p.
24. Stein, A., Van der Meer F., Gorte B. *Spatial Statistics for Remote Sensing*. Dordrecht: Springer Netherlands, 2002, 301 p.
25. Townshend J., HuangC., Kalluri S., et al. Beware of per-pixel characterization of land cover. *International Journal Remote Sensing*, 2000, vol. 21, no. 4, p. 839–843.
26. Tso, B., Mather, P.M. *Classification methods for remotely sensed data*. CRC Press, 2009, 378 p.
27. Vapnik, V. *The Nature of Statistical Learning Theory*. Springer-Verlag New York, 1995. 314 p.
28. Woodcock C., Strahler A., Jupp D. The use of variograms in remote sensing I. Scene models and simulated images. *Remote sensing of environment*, 1988, vol. 25, p. 323 - 348.
29. Woodcock C., Strahler A., Jupp D. The use of variograms in remote sensing. II - Real digital images. *Remote sensing of environment*, 1988, vol. 25, p. 349–379.
30. Zimmerman D.L., Zimmerman, B. A. Comparison of Spatial Semivariogram Estimators and Corresponding Ordinary Kriging Predictors. *Technometrics*, 1991, vol. 33, no. 1, p. 77–91.

## 1 PRIEDAS. MATLAB FUNKCIJOS

```

function paramdata = ClassesParam(paramdata,r)
%calculates variogram fuction parameters
%observation with no local max - local max as last variogram value
%paramdata - dataset with variogram values, local maxs and classes indx
%h - no of lags
%paramdata = tmp;
    tmp = paramdata.disp; tmp1 = paramdata.V2; tmp2 = paramdata.V1;
    paramdata.RVF = tmp./tmp2;
    paramdata.RSF = tmp1./tmp2;
    clear tmp tmp1 tmp2;
    paramdata.SDT = (paramdata.V4 - 2*paramdata.V3 - paramdata.V2); %/ r^2;
    paramdata.FDO = (paramdata.V2-paramdata.V1); %/r;
%init peaks parameters
    paramdata.FML = 0; paramdata.FML(:) = 0;
    paramdata.MFM = 0; paramdata.MFM(:) = 0;
    paramdata.DMF = 0; paramdata.DMF(:) = 0;
    paramdata.VMF = 0; paramdata.VMF(:) = 0;
    paramdata.RMM = 0; paramdata.RMM(:) = 0;
    paramdata.SDF = 0; paramdata.SDF(:) = 0;
    paramdata.DMS = 0; paramdata.DMS(:) = 0;

    for i = 1:size(paramdata,1)
        if paramdata.max1(i) > 0
            %local maximum as local max with thres
            if double(paramdata(i,paramdata.loc1(i))) - 0.01 <
double(paramdata(i,paramdata.loc1(i)+1))
                paramdata.max1(i) = paramdata(i,r);
                paramdata.loc1(i) = r;
            end
            %second maximum parameters
            if paramdata.max2(i) > 0
                if double(paramdata(i,paramdata.loc2(i))) - 0.01 <
double(paramdata(i,paramdata.loc2(i)+1))
                    paramdata.max2(i) = paramdata.max1(i);
                    paramdata.loc2(i) = paramdata.loc1(i);
                    %paramdata.DMS(i) = 0;
                end
                if paramdata.max2(i) == 0
                    paramdata.max2(i) = paramdata.max1(i);
                    paramdata.loc2(i) = paramdata.loc1(i);
                end
                paramdata.DMS(i) = paramdata.loc2(i) - paramdata.loc1(i);
            end
            %treat obs with no local max
            else
                paramdata.max1(i) = paramdata(i,r);
                paramdata.loc1(i) = r;
            end
            %first maximum parameters
            tmp1(i) = sum(double(paramdata(i,1:paramdata.loc1(i))));
            tmp2(i) = paramdata.max1(i);
            tmp3(i) = paramdata.loc1(i);
            paramdata.FML(i) = tmp3(i);
            paramdata.MFM(i) = tmp1(i)./tmp3(i);
            paramdata.DMF(i) = paramdata.MFM(i) - paramdata.V1(i);
            tmp4(i) = sum((double(paramdata(i,1:paramdata.loc1(i)))-
paramdata.MFM(i)).^2);
            paramdata.VMF(i) = tmp4(i)./tmp3(i);
            paramdata.RMM(i) = (tmp2(i)*tmp3(i))./tmp1(i);
        end
    end

```

```

        paramdata.SDF(i) = tmp2(i) + paramdata.V1(i) - 2 *
double(paramdata(i, floor(tmp3(i) ./ 2)));
    end

    paramdata.max1 = [];
    paramdata.max2 = [];
    paramdata.loc1 = [];
    paramdata.loc2 = [];

end

function paramdata = ClassesVariogram(P,band,r,label)
    %P = imread('class1.jpg');
    P = P(:, :, band);
    %r = 6; % Lag range;
    %ClassNo = 1;
    %image band to matrix with variogram values
    [VM, VD, VS, VP] = vagram(P,r);
    %3dim matrix to 2dim
    var = VarParam(VP,r);
    class = zeros(size(var,1),1);
    class(:) = label;
    disp = VarParam(VD,1);
    disp = disp(:,1);
    mean = VarParam(VM,1);
    mean = mean(:,1);
    std = VarParam(VS,1);
    std = std(:,1);
    param = [var class disp mean std];
    %remove negative values(image margins)
    [negrows,~]=find(param==-1);
    param2 = param(setdiff(1:size(param,1),negrows),:);
    %param2(:,size(param2,2)) = [];
    %param2(:,size(param2,2)-1) = [];
    %find var peaks
    peaks = zeros(size(param2,1),4);
    %disp(label);
    for i = 1:size(param2,1)
        [tmp_peaks, tmp_locs] = findpeaks([param2(i,1:r)]);
        if size(tmp_peaks,2) == 1
            peaks(i,:) = [tmp_peaks 0 tmp_locs 0];
        end
        if size(tmp_peaks,2) == 2
            peaks(i,:) = [tmp_peaks tmp_locs];
        end
    end
    end
    param2 = [param2 peaks];
    %create parameters dataset
    paramdata = dataset({param2
'V1', 'V2', 'V3', 'V4', 'V5', 'V6', 'row', 'col', 'class', 'disp', 'mean', 'std',
'max1', 'max2', 'loc1', 'loc2'});
end

function error = efektyvumas(PP,map2)
    accoverall = (numel(PP) - nnz(PP-map2)) / numel(PP);
    error = confusionmat(PP(:),map2(:));
    error0 = (1-eye(7)).*error;
    error(:,end+1) = sum(error0,2);
    error(end+1,:) = [sum(error0) 0];
    clear error0;
end

```

```

function PksLoc = FindPeaks(data,l)
%create peaks matrix
tmp = double(data(:,1:l));
PksLoc = zeros(size(tmp,1),4);
for i=1:size(tmp,1)
    %tmp = double(datafull(i,1:6));
    [pks, loc] = findpeaks(tmp(i,:));
    if size(pks) > 0
        PksLoc(i,1) = pks(1);
        PksLoc(i,2) = loc(1);
    end
    if size(pks) > 1
        PksLoc(i,3) = pks(2);
        PksLoc(i,4) = loc(2);
    end
end
end

function PP = glodintuvas(P,n)

PP = zeros(size(P));
PP = colfilt(P,[n n],'sliding',@mode);
PP = PP + (PP == 0).*P;

End

P = map2;

figure('units','normalized','outerposition',[0 0 1 1]);
subplot(1,2,1); imshow(label2rgb(P));
subplot(1,2,2);
n = 5;
%for k = 1:20;
for k = 1:2;
    P = glodintuvas(P,n);
    imshow(label2rgb(P));
    title(sprintf('Iteracija %d',k));
    getframe;
    pause(1.5);
end;

function RandomVariogram(n,lags, data, lab)
%plot random variogram
%n - no of variograms to plot, lags - no of variogram values, data
    for i = 1:n
        %plot(0:lags,[0; smooth(double(data(1,1:lags)))], 'LineWidth',0.5);
%smoothing
        plot(0:.1:lags,spline(0:lags,[0 double(data(randi([1
size(data,1)],1,1),1:lags))],0:.1:lags), 'LineWidth',0.5); %spline
        %plot(0:lags,[0 double(data(randi([1
size(data,1)],1,1),1:lags))], 'LineWidth',0.5); %estimated
        hold on;
    end
    xlabel('h'), ylabel('\gamma(h)'), title(lab)
end

function [sample,test] = SplitData(data,nclasses)

sample=[];

```

```

test=[];
for i = 1:nclasses
    tmp = data((data(:,1)==i),:);
    [ind1,ind2,ind3] = dividerand(size(tmp,1),0.3,0.7,0);
    sample = [sample; tmp(ind1,:)];
    test = [test; tmp(ind2,:)];
end

end

function [best_C,best_gamma] = SVMParamSelection(lab, dat, nfold,par1,par2)
%cross-validate using one-vs-all approach
%lab - pikseliu klases, dat - pikseliu parametrai,
%nfold - kryzminio patikrinimo sluoksniu skaicius,
%par1 - C parametrai , par2 - gamma parametrai

%grid of parameters
%nfold = 5;
%par1 = -5:2:15;
%par2 = -15:2:3;
[C,gamma] = meshgrid(par1, par2);
acc = zeros(numel(C),1);
d=2;
labels = unique(lab);
numLabels = numel(labels);
for i=1:numel(C)
    % one vs. one
    %acc(i) = svmtrain(lab,dat, sprintf('-c %f -g %f -v %d -t %d -h
0', 2^C(i), 2^gamma(i), nfold,d));
    %one vs. one
    acc(i) = libsvmcrossval_ova(lab, dat, sprintf('-s 0 -t 2 -c %f -
g %f -h 0', 2^C(i), 2^gamma(i)), nfold);
    %one vs. one linear
    %acc(i) = libsvmcrossval_ova(lab, dat, sprintf('-s 0 -t 0 -c %f
-h 0', 2^C(i), 2^gamma(i)), nfold);
    disp(['Lapes i = ' num2str(i)]);
end
%pair (C,gamma) with best accuracy
[~,idx] = max(acc);
%contour plot of paramter selection
contour(C, gamma, reshape(acc,size(C))), colorbar
hold on;
text(C(idx), gamma(idx), sprintf('Tikslumas = %.2f
%%',acc(idx)), 'HorizontalAlign','left', 'VerticalAlign','top')
hold off
xlabel('log_2(C)'), ylabel('log_2(\gamma)'), title('Kryzminis
patikrinimas')
%best_C and best_gamma
best_C = 2^C(idx); best_gamma = 2^gamma(idx);
end

function [VM, VD, VS, VP] = vagram(P,r)

n = 2*r+1; % Block width;
P = double(P);

VP = -1*ones(size(P,1),size(P,2),r);
VD = -1*ones(size(P,1),size(P,2));
VM = -1*ones(size(P,1),size(P,2));
VS = -1*ones(size(P,1),size(P,2));
for i = r+1:size(P,1)-r;
for j = r+1:size(P,2)-r;

```

```

        [VM(i,j), VD(i,j), VS(i,j), VP(i,j,:)] = gamma(P(i-r:i+r,j-r:j+r));

end;
end;

function [M, D, S, V] = gamma(P) % Variogram
V = zeros(1,r);
K = -n^2*ones(1,r);
for ii = 1:n;
for jj = 1:n;
    PP = (P - P(ii,jj)).^2;
    for h = 1:r;
        for p = -1:1;
            for q = -1:1;
                w1 = ii + h*p;
                w2 = jj + h*q;
                if w1 >= 1 && w1 <= n;
                    if w2 >= 1 && w2 <= n;
                        V(h) = V(h) + PP(w1,w2);
                        K(h) = K(h) + 1;
                    end;
                end;
            end;
        end;
    end;
end;
end;

V = .5*V./K;
D = var(P(:));
M = mean(P(:));
S = std(P(:));
end

end

function indices = crossvalidation(y, nfold)
%stratified n-fold cross-validation
%indices = crossvalind('Kfold', y, nfold);
cv = cvpartition(y, 'kfold', nfold);
indices = zeros(size(y));
for i=1:nfold
    indices(cv.test(i)) = i;
end
end

function acc = libsvmcrossval(y, X, opts, nfold, indices)
if nargin < 3, opts = ''; end
if nargin < 4, nfold = 10; end
if nargin < 5, indices = crossvalidation(y, nfold); end

%N-fold cross-validation testing
acc = zeros(nfold,1);
for i=1:nfold
    testIdx = (indices == i); trainIdx = ~testIdx;
    mdl = libsvmtrain_ova(y(trainIdx), X(trainIdx,:), opts);
    [~,acc(i)] = libsvmpredict_ova(y(testIdx), X(testIdx,:), mdl);
end
acc = mean(acc); %average accuracy
end

function [pred,acc,prob] = libsvmpredict(y, X, mdl)

```



```

%classes
labels = mdl.labels;
numLabels = numel(labels);

%get probability estimates of test instances using each 1-vs-all model
prob = zeros(size(X,1), numLabels);
for k=1:numLabels
    [~,~,p] = svmpredict(double(y==labels(k)), X, mdl.models{k}, '-b 1 -
q');
    prob(:,k) = p(:, mdl.models{k}.Label==1);
end

%predict the class with the highest probability
[~,pred] = max(prob, [], 2);
% classification accuracy
acc = mean(pred == y);
end

function mdl = libsvmtrain(y, X, opts)
    if nargin < 3, opts = ''; end

    %classes
    labels = unique(y);
    numLabels = numel(labels);

    %train one-against-all models
    models = cell(numLabels,1);
    for k=1:numLabels
        models{k} = svmtrain(double(y==labels(k)), X, strcat(opts,' -b 1 -
q'));
    end
    mdl = struct('models',{models}, 'labels',labels);
end

```