



Kauno technologijos universitetas

Informatikos fakultetas

**Vaizdų dekompozicijos ir giliojo mokymosi algoritmų taikymo
orto vaizdų analizėje tyrimas**

**Analysis of Deep Learning and Image Decomposition
Algorithms for Ortho Image Processing**

Magistrinis darbas

Arminas Šidlauskas

Projekto autorius

Doc. Dr. Andrius Kriščiūnas

Projekto vadovas

Kaunas, 2023



Kauno technologijos universitetas

Informatikos fakultetas

**Vaizdų dekompozicijos ir giliojo mokymosi algoritmų taikymo
orto vaizdų analizėje tyrimas**

Baigiamasis magistro studijų projektas

Arminas Šidlauskas

Projekto autorius

Doc. Dr. Andrius Kriščiūnas

Vadovas

Kaunas, 2023



Kauno technologijos universitetas

Informatikos fakultetas

Vaizdų dekompozicijos ir giliojo mokymosi algoritmų taikymo orto vaizdų analizėje tyrimas

Baigiamasis magistro studijų projektas
Programų sistemų inžinerija(6211BX011)

Arminas Šidlauskas

Projekto autorius

Doc. dr. Andrius Kriščiūnas

Vadovas

Prof. dr. Agnė Paulauskaitė-Tarasevičienė

Recenzentė

Kaunas, 2023



Kauno technologijos universitetas

Informatikos fakultetas

Arminas Šidlauskas

Vaizdų dekompozicijos ir giliojo mokymosi algoritmų taikymo orto vaizdų analizėje tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Arminas Šidlauskas

Patvirtinta elektroniniu būdu



Kauno technologijos universitetas

Informatikos fakultetas

Baigiamojo magistro projekto užduotis

Projekto tema

Vaizdų dekompozicijos ir giliojo mokymosi algoritmų taikymo orto vaizdų analizėje tyrimas

Reikalavimai ir sąlygos
(tikslinti pavadinimą
pagal poreikį)

Vadovas

(vadovo pareigos, vardas, pavardė, parašas)

(data)

Arminas Šidlauskas. Vaizdų dekompozicijos ir giliojo mokymosi algoritmų taikymo orto vaizdų analizėje tyrimas. Magistro baigiamasis projektas vadovas Doc. dr. Andrius Kriščiūnas; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Programų sistemų inžinerija.

Reikšminiai žodžiai: mašininis mokymasis, semantinis segmentavimas, objektų aptikimas, nuotolinis stebėjimas, „Sentinel“ vaizdai, bepiločių orlaivių vaizdai.

Kaunas, 2023. 57 p.

Santrauka

Nuotolinio stebėjimo metodai leidžia stipriai pagerinti lauko tyrimų našumą suteikdami galimybę greitai ir patogiai rinkti informaciją nuotoliu. Naudojant palydovinius vaizdus, bepiločių orlaivių vaizdus ir kitus nuotolinio stebėjimo metodus, tyrėjai gali palengvinti duomenų rinkimą ir klasifikavimą. Darbo metu kuriama nuotolinio stebėjimo sistema skirta palengvinti miškingumo stebėjimą ir upės riedulių klasifikavimą pasitelkiant nuotolinio stebėjimo metodus. Sukūrus sistemą atliekami trys tyrimai – automatiškai generuotų duomenų rinkinių miško klasifikavimo modeliams mokytis tinkamumas, skirtingų palydovo spektrinių juostų kombinacijų įtaka miškingos teritorijos klasifikavimo modeliams ir upės riedulių klasifikavimo galimybių tyrimas. Pirmojo tyrimo metu nustatyta, kad automatiškai sugeneruoti duomenų rinkiniai iš atvirai prieinamų duomenų leidžia pasiekti aukšto tikslumo klasifikavimo rezultatus ($\sim 0,92$ PA ir $\sim 0,84$ mIoU). Antrojo tyrimo metu nustatyta, kad skirtingos spektrinių juostų kombinacijos gali įtakoti klasifikavimo modelius. Kombinacija naudojanti artimųjų infraraudonųjų spindulių ir regimosios šviesos kombinacijas pasiekė aukščiausią tikslumą ($0,96$ PA ir $0,88$ mIoU). Galiausiai atliktas upės riedulių klasifikavimo tyrimas nurodė aukšta upės riedulių virš vandens klasifikavimo tikslumą ($\sim 0,776$ P) ir vidutinius atpažinimo rezultatus ($\sim 0,690$ R). Kita vertus riedulių po vandeniu klasifikavime pasiektas vidutinis tikslumo rezultatas ($\sim 0,633$ P), bet atpažinimo rezultatai buvo žemi ($\sim 0,391$ R).

Arminas Šidlauskas. Analysis of Deep Learning and Image Decomposition Algorithms for Ortho Image Processing. Master's Final Degree Project supervisor assoc. Prof. Andrius Kriščiūnas; Kaunas University of Technology.

Study field and area (study field group): Software engineering.

Keywords: machine learning, semantic segmentation, object detection, remote sensing, sentinel satellites, drone images.

Kaunas, 2023. 57 pages.

Summary

Remote sensing techniques can greatly improve the efficiency of field surveys by enabling to remotely collect information quickly and conveniently. Using satellite imagery, unmanned aerial vehicles and other remote sensing techniques, researchers can facilitate data collection and classification. The remote-sensing system being developed in this thesis is designed to facilitate the monitoring of forest cover and the classification of river boulders using remote-sensing techniques. The development of the system leads to three studies: the suitability of automatically generated datasets for training forest classification models, the impact of different combinations of satellite spectral bands on forest classification models, and a study of the feasibility of classifying river boulders. In the first study, it was found that automatically generated datasets from openly available data allow to achieve high accuracy classification results (~ 0.92 PA and ~ 0.84 mIoU). The second study found that different combinations of spectral bands can influence classification patterns. The combination of near-infrared and visible light achieved the highest accuracy (0.96 PA and 0.88 mIoU). Finally, a study on the classification of river boulders indicated high classification accuracy (~ 0.776 P) and average recall rates (~ 0.690 R) for river boulders over water. On the other hand, the classification of boulders under water showed an average precision results (~ 0.633 P) but low recall rates (~ 0.391 R).

Turinys

Paveikslų sąrašas	9
Lentelių sąrašas	11
Santrumpų ir terminų sąrašas	12
Įvadas	14
1. Analizė	15
1.1. Srities apžvalga.....	15
1.2. Galimybių vertinimas.....	16
1.3. Atrinkti metodai ir technologijos.....	30
1.4. Egzistuojančių rinkoje sistemų vertinimas.....	31
2. Projektinė dalis	33
2.1. Konceptas.....	33
2.2. Funkciniai reikalavimai.....	34
2.3. Nefunkciniai reikalavimai.....	35
3. Tyrimas	38
3.1. Miškingumo tyrimas.....	38
3.2. Upės riedulių tyrimas.....	43
4. Eksperimentas	46
4.1. Miškingumo eksperimentas.....	46
4.2. Upės riedulių eksperimentas.....	50
5. Išvados	53
Literatūros sąrašas	54
Priedai	57
1 Priedas. Pristatytas mokslinis straipsnis 27-oji tarptautinėje informacinių technologijų konferencijoje „IVUS 2022“ Šidlauskas A., Kriščiūnas A. (2022). Pixel-based Forest classification of Sentinel-2 images using automatically generated datasets.....	57
2 Priedas. Paskelbtas mokslinis straipsnis CA WoS duomenų bazėje referuojamame žurnale „Water“ Akstinas V., Kriščiūnas A., Šidlauskas A., Čalnerytė D., Meilutytė-Lukauskienė D., Jakimavičius D., Fyleris T., Nazarenko S., Barauskas R. (2022). Determination of River Hydromorphological Features in Low-Land Rivers from Aerial Imagery and Direct Measurements Using Machine Learning Algorithms.....	57

Paveikslų sąrašas

1.1 pav. <i>LandSat</i> palydovinis vaizdas, Peru [6]	16
1.2 pav. Palydovinių vaizdų surinkti duomenys a) S1 vaizdas (Klaipėdos regionas) b) S2 vaizdas (Kauno regionas).....	18
1.3 pav. Dažnai naudojamas CNN [11]	19
1.4 pav. Konvoliucinis sluoksnis [12]	20
1.5 pav. Sujungimo sluoksnio pavyzdys, įgyvendinamas didžiausias sujungimas	20
1.6 pav. Objektų aptikimas [13]	21
1.7 pav. Fast R-CNN architektūra [14].....	22
1.8 pav. YOLOv5 architektūra. Susideda iš trejų dalių: pagrindinė (angl. <i>Backbone</i>) sudaro <i>CSPDarknet</i> tinklo architektūra, kaklo (angl. <i>Neck</i>) sudaro <i>PANet</i> tinklo architektūra ir galvos (angl. <i>Head</i>) sudaro <i>YOLO</i> sluoksnio architektūra [16].....	22
1.9 pav. Pilnai konvoliucinis tinklas (FCN), pritaikytas semantinei segmentacijai [19]	24
1.10 pav. PSP tinklo architektūra. Turint įvesties vaizdą (a), pirmiausia CNN pagalba gaunamas paskutinio konvoliucinio sluoksnio požymių žemėlapis (b), tada taikomas piramidės skaidymo modulis, kad būtų galima surinkti įvairių mažesnių vaizdus, po to seka didinamasis sluoksnis ir jungiamasis sluoksnis, kad būtų suformuotas galutinis požymių atvaizdas, kuriame pateikiama tiek vietinio, tiek visuotinio konteksto informacija (c). Galiausiai ši reprezentacija perduodama į konvoliucijos sluoksnį, kad būtų gauta galutinė vieno taško prognozė (d) [20].....	24
1.11 pav. Deeplabv3+ architektūra. Kodavimo modulis koduoja daugialypę kontekstinę informaciją, taikydamas kelių mastelių išplėstinę konvoliuciją, o paprastas, bet veiksmingas dekoderio modulis patikslina segmentavimo rezultatus pagal objektų ribas [21].	25
1.12 pav. Vaizdų apdorojimo greitis pagal pateikiamą imtį [25]	28
2.1 pav. Miškingumo klasifikavimo sistemos dalis.....	33
2.2 pav. Upės riedulių klasifikavimo sistemos dalis	34
2.3 pav. Panaudos atveju diagrama	35
3.1 pav. Sudaryta Lietuvos mozaika a) TCI vaizdas b) FCI vaizdas c) SWI vaizdas.	39
3.2 pav. Atsitiktiniu būdu sugeneruoti taškai Lietuvos teritorijoje. Vaizde pateikiama 1600 taškų. ..	40
3.3 pav. S2 vaizdas ir sukurtos miško (žalia) ir ne miško (juoda) kaukės; a) tikros spalvos vaizdas (TCI), 10m skiriamoji geba b) iš OSM duomenų sukurtos kaukės c) iš HRL duomenų sukurtos kaukės	41
3.4 pav. Duomenų rinkinių pavyzdžiai 1) Kompozito vaizdas 2) HRL vaizdo kaukė. Raidės indikuoja skirtingus duomenų rinkinius a) TCI kompozito b) FCI kompozito c) SWI kompozito.....	42
3.5 pav. Drono fiksuotas vaizdas (Vadagiai).....	43
3.6 pav. Klasifikuoti rieduliai upėje (Vadagiai), žalia spalva žymi BAW klasę, raudona BUW klasę	44
3.7 pav. Upės išskaidymas į ruožus.....	44
3.8 pav. <i>K</i> kartų kryžminė patikra. Raudona spalva pažymėtos mokymo aibės, geltona spalva validacijos aibės. Vaizde pateikiamas 3 kartų kryžminės patikros pavyzdys.	45
4.1 pav. Validacijos rezultatai mokymosi metu su skirtingais duomenų rinkiniais a) matuojama taškų tikslumu (PA) b) matuojama pagal vidutinį sankirtos koeficientą (mIoU)	46
4.2 pav. Apmokyto modelio klasifikavimo pavyzdžiai a) S2 vaizdai, 10m erdvinė skiriamoji geba b) klasifikavimas, modelis apmokytas su OSM duomenimis c) klasifikavimas, modelis apmokytas su HRL duomenimis.....	48
4.3 pav. Validacijos rezultatai mokymosi metu. Melyna spalva žymimi SWI kompozito rezultatai, orandžinė FCI kompozito ir žalia TCI kompozito. Viršuje pateikiamas vaizdo taškų tikslumas (PA),	

apačioje vidutinis sankirtos koeficientas (mIoU) a) pateikiamos metrikos skalėje nuo 0 iki 1 b) pateikiamos metrikos skalėje nuo 0,7 iki 1,0	49
4.4 pav. Kryžminės validacijos mokymosi metrikos a) tikslumo ir b) atpažinimo. Pilka spalva nurodo specifinę kryžminę validaciją, raudona spalva vidutinę reikšmę.....	51
4.5 pav. a) Originalus vaizdas b) Raudona ir žalia spalva nusako rankinių būdų sužymėtus riedulius BAW(raudona) ir BUW (žalia). Kryžminės linijos rodo atitinkamai BAW ir BUW automatinio klasifikavimo rezultatus.	52

Lentelių sąrašas

1.1 lentelė S2 palydovų spektrinės juostos [7]	17
2.1 lentelė Įgyvendinimo pasitenkinimo įverčiai	35
2.2 lentelė Neįgyvendinimo nepasitenkinimo įverčiai	36
2.3 lentelė. Aiškaus atvaizdavimo nefunkcinis reikalavimas	36
2.4 lentelė. Patogaus atvaizdavimo nefunkcinis reikalavimas	36
2.5 lentelė. Kalbos nefunkcinis reikalavimas	36
2.6 lentelė. Kvotos likučio stebėjimo nefunkcinis reikalavimas	37
2.7 lentelė. Pritaikymo veikti skirtingose operacinėse sistemose nefunkcinis reikalavimas.....	37
2.8 lentelė. Koordinačių sistemos konvertavimo nefunkcinis reikalavimas	37
3.1 lentelė Spektrinių juostų kombinacijų sudarymas (pagal 1.2.1.2 skyrelyje pateikiamas spektrines juostas)	38
3.2 lentelė Riedulių bendras pasiskirstymas per visus vaizdus pagal poaibį.....	45
4.1 lentelė Testavimo rezultatai vertinant pagal HRL testavimo duomenų rinkinį.....	47
4.2 lentelė Testavimo rezultatai vertinant pagal OSM testavimo duomenų rinkinį	47
4.3 lentelė Testavimo rezultatai pagal kompozitus	49
4.4 lentelė Skirtingų modelių tikslumo palyginimas (naudojant <i>train1245-valid3</i> duomenų rinkinį). Vertinamos abi klasės.	50
4.5 lentelė Objektų kiekis, tikslumas ir atpažinimas pagal duomenų rinkinį	51

Santrumpų ir terminų sąrašas

Santrumpos:

RGB – spalvų maišymo schema, kai naudojamos trys juostos – raudona (angl. *red*), žalia (angl. *green*) ir mėlyna (angl. *blue*).

ESA (angl. *European Space Agency*) – Europos kosmoso agentūra.

NASA (angl. *National Aeronautics and Space Administration*) – JAV Nacionalinė aeronautikos ir kosmoso administracija.

USGS (angl. *United States Geological Survey*) – Jungtinių Valstijų geologijos tarnyba.

CNN (angl. *Convolutional Neural Networks*) – konvoliuciniai neuroniniai tinklai.

S1 (angl. *Sentinel-1*) – Copernicus programos viena iš palydovų misijų.

S2 (angl. *Sentinel-2*) – Copernicus programos viena iš palydovų misijų.

VNIR (angl. *Visible and near infrared*) – regimoji ir artimoji infraraudonoji spinduliuotė.

SWIR (angl. *Short wave infrared*) – trumpųjų bangų infraraudonieji spinduliai.

OSM (angl. *OpenStreetMap*) – atvirai prieinama geografinių dumenų bazė, kurią atnaujinama ir prižiūri savanoriai.

Fast R-CNN (angl. *Fast Region-based Convolutional Neural Network*) – objektų aptikimo architektūros tipas.

YOLOv5 (angl. *You Only Look Once version 5*) – objektų aptikimo architektūros tipas.

FCN (angl. *Fully Convolutional Networks*) – pilnai konvoliucinis tinklas, semantinės segmentacijos modelio architektūros tipas.

PSP (angl. *Pyramid Scene Parsing*) – piramidinis scenos skaidymas, semantinės segmentacijos modelio architektūros tipas.

ResNet-50 (angl. *Residual Network with 50 layers*) – semantinės segmentacijos architektūros pagrindo dalis.

ResNet-101 (angl. *Residual Network with 101 layers*) – semantinės segmentacijos architektūros pagrindo dalis.

HRL (angl. *High Resolution Layers*) – Copernicus programos teikiami klasifikavimo sluoksniai. Klasifikacija gali apimti įvairius aspektus: miškingumas, ledo padengimas, pakrantės ir t.t.

LiDAR (angl. *Light Detection and Ranging*) – nuotolinio stebėjimo technologija, kuri naudoja lazerio šviesą atstumams matuoti ir tiksliams trimačiams objektų ir aplinkos žemėlapiams sudaryti.

LEI – Lietuvos Energetikos Institutas.

TCI – vaizdo spektrinių juostų kombinacija sudaryta iš RGB schemas (angl. *True Color Image*).

FCI – vaizdo spektrinių juostų kombinacija sudaryta iš RGB ir artimųjų infraraudonųjų spindulių schemos (angl. *False Color Image*).

SWI – vaizdo spektrinių spektrinių juostų kombinacija sudaryta iš RGB, artimųjų infraraudonųjų spindulių ir infraraudonųjų spindulių schemos (angl. *Short-Wave Infrared*).

BAW (angl. *Boulders Above Water*) – rieduliai virš vandens.

BUW (angl. *Boulders Under Water*) – rieduliai po vandeniu.

Terminai:

Klasifikacija – objektų skirstymas į klases pagal esminius požymius.

Lauko tyrimas – duomenų rinkimas iš tiesioginių šaltinių.

Nuotolinis tyrimas – duomenų rinkimas taikant nuotolinius metodus, stebėjimų atlikimas naudojant palydovo, lėktuvo vaizdus.

Vaizdo triukšmas – įvairaus pobūdžio nepageidaujama informacija kuri gali atsidurti vaizduose.

Pakartotinis fiksavimas – apibūdina, kaip dažnai fiksuojama nuotrauka toje pačioje vietoje.

Semantinis segmentavimas – vaizdo identifikavimo metodas, kurio metu yra kiekvienam vaizdo taškui priskiriama klasė.

Objektų aptikimas – vaizdo identifikavimo metodas, kurio metu yra išskiriami ir lokalizuojami objektai vaizde (pvz. dviratis, automobilis).

Kompozitas (lot. *compositus*) – sudarytas iš kelių dalių. Kalbant apie vaizdus, vaizdas sudarytas iš skirtingų spektrinių juostų kombinacijų.

Įvadas

Nuotolinis stebėjimas yra vertinga priemonė, kurią galima naudoti duomenims rinkti ir pokyčiams įvairiose aplinkose stebėti. Ji apima lėktuvuose, palydovuose ar dronuose esančių jutiklių naudojimą duomenims rinkti per atstumą, nereikalaujant tiesioginės žmogaus sąveikos su tirama teritorija [1]. Vienas iš pagrindinių nuotolinio stebėjimo privalumų – galimybė greitai ir ekonomiškai efektyviai aprėpti dideles teritorijas, todėl tai yra veiksmingesnis ir ekonomiškesnis metodas, lyginant su lauko tyrimais, kurie gali užimti daug laiko ir būti brangūs, ypač didelėse teritorijose [2]. Naudojant mašininį mokymąsi, nuotolinio stebėjimo duomenis galima analizuoti taikant procesą kurio metu mokomi algoritmai, automatiškai klasifikuojantys įvairius duomenų požymius. Taip galima gauti dar tikslesnės ir aktualesnės informacijos apie žemės dangą, augmeniją ir žemės panaudojimą. Nuotolinis stebėjimas taip pat gali būti naudojamas pokyčiams stebėti, todėl mokslininkai gali stebėti duomenų tendencijas ir dėsningumus [3].

Svarbu sukurti nuotolinių stebėjimų programinę įrangą, kuri gebėtų tiksliai stebėti žemės naudojimą, dėl keleto priežasčių. Tikslūs žemės naudojimo duomenys yra svarbūs kelioms programoms, tarp jų žemės naudojimo planavimas, išteklių valdymas ir aplinkos poveikio vertinimas [4], [5].

Automatizuota sistema turėtų pasižymėti, kaip įmanoma didesniu tikslumu ir turi gebėti atlikti didelių teritorijų automatinį klasifikavimą.

Tikslas ir uždaviniai

Pagrindinis šio darbo tikslas – supaprastinti duomenų rinkimo procesą taikant automatizuotus nuotolinio stebėjimo metodus. Naudojant šiuos metodus siekiama sudaryti sąlygas automatiškai rinkti ir klasifikuoti nuotolinio stebėjimo duomenis, taip supaprastinant ir pagreitinant duomenų rinkimo procesą.

Keliami uždaviniai:

1. Sukurti miškų ir upių objektų klasifikavimo sistemą, kuri, pritaikydama mašininio mokymosi sprendimus identifikuotų miškingas teritorijas ir klasifikuotų upėje esančius riedulius kurie gali įtakoti upės tėkme;
2. Ištirti mašininio mokymosi modelių, skirtų miško plotams klasifikuoti, parengimo galimybes;
3. Ištirti upės riedulių klasifikavimo galimybes taikant mašininio mokymosi modelius.

1. Analizė

1.1. Srities apžvalga

1.1.1. Orto vaizdai

Orto vaizdai (arba ortofoto) – tai apdorotos lėktuvų ar palydovų nuotraukos, kurias galima naudoti kaip tikslus žemėlapius. Apdorojimo procese pašalinamas fotoaparato posvyrio, topografinio reljefo ir kitų vaizdo iškreipimo šaltinių poveikis, todėl gaunamas vienodo mastelio ir tikslus geometrinis žemės paviršiaus vaizdas. Orto vaizdai gali būti naudojami žemės naudojimo, miestų augimo ir aplinkos sąlygų pokyčiams laikui bėgant stebėti. Jie ypač naudingi žemės valdymui ir planavimui, pavyzdžiui, nustatant augalijos dangos plotus, stebint urbanizaciją ir miestų plitimą, sudarant potvynių zonų žemėlapius. Be to, jie gali būti naudojami žemės ūkyje, be kita ko, pasėlių valdymui, dirvožemio drėgmės ir derliaus žemėlapių sudarymui.

1.1.2. Orto vaizdų gavimas

Egzistuoja keletas šaltinių, iš kurių galima gauti įvairioms reikmėms skirtų orto vaizdų. Vienas iš tokių šaltinių yra NASA (angl. *National Aeronautics and Space Administration*) atvirai prieinami palydoviniai vaizdai. Pavyzdžiui, programa *Landsat* teikia didelės skiriamosios gebos daugiaspektrinius Žemės paviršiaus vaizdus, kuriuos galima naudoti žemės stebėsenai, gamtos išteklių valdymui ir miestų planavimui. Vaizdus fiksuoja *Landsat* palydovai, kuriuos bendrai valdo NASA ir USGS (angl. *United States Geological Survey*) [6].

Kitas orto vaizdų šaltinis yra *Sentinel* palydovai, kurie yra Europos Sąjungos Žemės stebėjimo programos *Copernicus* dalis. Šie palydovai teikia didelės skiriamosios gebos optinius ir radarinius Žemės paviršiaus vaizdus, kurie gali būti naudojami įvairioms reikmėms, įskaitant žemės stebėseną, nelaimių valdymą ir aplinkos stebėseną [7].

Be palydovinių vaizdų, orto vaizdus taip pat galima rinkti naudojant dronus. Dronai, kuriuose įrengtos kameros, gali fiksuoti didelės skiriamosios gebos žemės vaizdus, kuriuos apdorojus galima sukurti orto vaizdus. Šis metodas ypač naudingas norint gauti išsamius nedidelių teritorijų arba sunkiai prieinamų vietovių vaizdus naudojant tradicinius aerofotografavimo metodus [8].

1.1.3. Vaizdų klasifikavimas


Vaizdų klasifikavimas – tai užduotis, kuria siekiama įvesties vaizdui priskirti kategoriją. Objektų aptikimas yra vaizdų klasifikavimo rūšis, kai ne tik nustatomas objektų buvimas vaizde, bet ir jų buvimo vieta, nubrėžiant aplink juos ribinius laukus. Paprastai tai pasiekama naudojant giliojo mokymosi modelius, tokius kaip Fast R-CNN arba YOLO. Kita vertus, atliekant semantinį segmentavimą kiekvienam vaizdo taškui priskiriama kategorija ir taip pilnas vaizdo klasifikavimas. Šią užduotį galima atlikti naudojant CNN (angl. *Convolutional Neural Networks*) modelius, pavyzdžiui, U-Net arba FCN. Atsitiktinis miškas yra klasikinis mašininio mokymosi algoritmas, kuris taip pat gali būti naudojamas vaizdams klasifikuoti. Jis apima sprendimų medžių ansamblio kūrimą, kai kiekvienas medis mokomas pagal atsitiktinį mokymo duomenų ir požymių poaibį. Galutinė klasifikacija gaunama iš visų ansamblyje esančių medžių balsų daugumos.

1.2. Galimybių vertinimas

1.2.1. Palydovinių orto vaizdų gavimas

1.2.1.1. LandSat misijos

Landsat programa – tai serija žemės stebėjimo palydovų, kurie nuo XX a. septintojo dešimtmečio pradžios renka ir teikia Žemės paviršiaus vaizdus. Programą bendrai valdo USGS ir NASA. Palydovai *Landsat* fiksuoja žemės vaizdus regimosios, artimosios infraraudonosios, trumpųjų infraraudonųjų ir šiluminės infraraudonosios spinduliuotės bangų ilgiuose. Šie vaizdai naudojami įvairioms reikmėms, įskaitant žemės dangos ir žemėnaudos stebėseną, gamtos išteklių valdymą ir reagavimą į nelaimes. Palydovų duomenys yra laisvai prieinami visiems, todėl jie puikiai tinka atlikti nuolatinius tyrimus.



1.1 pav. *LandSat* palydovinis vaizdas, Peru [6]

Landsat palydovai turi kelias spektrines juostas, kuriomis fiksuojami skirtingo ilgio Žemės paviršiaus vaizdai. Pavyzdžiui, *Landsat 8* palydovas turi vienuolika spektrinių juostų, apimančių regimojo ir artimojo infraraudonojo spektro bangų ilgius, taip pat dvi šiluminės infraraudonosios spinduliuotės juostas. Palydovų vaizdų erdvinė skiriamoji geba, arba tikslumas, skiriasi priklausomai nuo spektrinės juostos. Panchromatinės spektrinių juostos skiriamoji geba yra didžiausia – jos vaizdo taško dydis yra 15 metrų, o kitų juostų vieno vaizdo taško skiriamoji geba yra 30 metrų. Šiluminių spektrinių juostų skiriamoji geba yra mažesnė – 100 metrų vienam vaizdo taškui [6]. Toks skiriamosios gebos kintamumas gali turėti įtakos duomenų tikslumui tam tikrais atvejais, pavyzdžiui, nustatant mažus žemės paviršiaus požymius arba stebint temperatūros pokyčius mažose teritorijose.

Landsat palydovai pateikia debesų kaukes, kurios naudojamos debesims ir šešėliams iš *Landsat* vaizdų atpažinti ir maskuoti. Debesų kaukės yra svarbios daugeliui nuotolinio stebėjimo programų, nes debesys ir šešėliai gali užgožti Žemės paviršiaus savybes ir sumažinti duomenų tikslumą. *Landsat* debesų kaukė paprastai sukurama naudojant algoritmus, kurie analizuoja *Landsat* vaizdų spektrinę ir erdvinę informaciją.

1.2.1.2. Sentinel misijos

Europos kosmoso agentūra paleido *Sentinel* serijos palydovus pagal ES programą *Copernicus*, kurios tikslas – teikti nemokamus, laisvai prieinamus Žemės stebėjimo duomenis, skirtus aplinkos stebėjimui,

nelaimių valdymui ir kitoms reikmėms. *Sentinel* misijas sudaro palydovų, kurie įvairiais jutikliais renka įvairius duomenis apie Žemės paviršių ir atmosferą. Palydovai teikia aukštos kokybės duomenis, pasižyminčius didele laiko ir erdvės skiriamąja geba, todėl jie yra vertingas šaltinis įvairioms taikomosioms programoms, įskaitant žemės naudojimo ir žemės dangos kartografavimą, gamtos išteklių valdymą ir klimato kaitos stebėseną. *Sentinel* misijos iš esmės pakeitė Žemės stebėjimo ir stebėsenos būdus, suteikdamos precedento neturinčią prieigą prie duomenų, kurie yra būtini mūsų planetos ištekliams suprasti ir valdyti.


Sentinel palydovai teikia įvairių spektrinių juostų su skirtinga erdvine skiriamąja geba vaizdus. Pavyzdžiui, S2 (angl. *Sentinel-2*) misija turi 13 spektrinių juostų, nuo regimosios iki artimosios infraraudonosios srities, o erdvinė skiriamoji geba svyruoja nuo 10 metrų iki 60 metrų vienam vaizdo taškui [7]. Dėl to šis prietaisas puikiai tinka įvairioms reikmėms, įskaitant žemės naudojimo stebėseną, augmenijos žemėlapių sudarymą ir aplinkos valdymą. S1 (angl. *Sentinel-1*) misija teikia radaro duomenis, kurių erdvinė skiriamoji geba yra nuo 5 metrų iki 100 metrų vienam vaizdo taškui, todėl galima stebėti Žemės paviršių pro debesis [7]. Šie duomenys ypač naudingi stebint jūros ledo ir vandenyno bangų pokyčius, taip pat sudarant žemės naudojimo žemėlapius ir nustatant infrastruktūros pokyčius. Misija *Sentinel-3* pateikia instrumentų rinkinį, kuriuo matuojami Žemės vandenynai, atmosfera ir sausumos paviršius, įskaitant jūros paviršiaus temperatūrą, vandenyno spalvą ir sausumos paviršiaus temperatūrą. *Sentinel-5P* misija matuoja įvairias atmosferos dujas, įskaitant azoto dioksidą, ozoną ir metaną, ir teikia svarbios informacijos apie oro kokybę ir klimato kaitą. Dėl didelės erdvinės ir spektrinės skiriamosios gebos *Sentinel* palydovai yra vertingas šaltinis įvairiems tikslams – nuo Žemės aplinkos stebėsenos iki klimato kaitos poveikio tyrimų.

1.1 lentelė S2 palydovų spektrinės juostos [7]


Spektrinė juosta	Rezoliucija (m)	Centrinis bangos ilgis (nm)	Aprašymas
B1	60	443	Ultra mėlyna krantinėms ir aerosoliams (angl. <i>Ultra blue coastal and aerosol</i>)
B2	10	490	Mėlyna (angl. <i>Blue</i>)
B3	10	560	Žalia (angl. <i>Green</i>)
B4	10	665	Raudona (angl. <i>Red</i>)
B5	20	705	VNIR
B6	20	740	VNIR
B7	20	783	VNIR
B8	10	842	VNIR
B8a	20	865	VNIR
B9	60	940	SWIR
B10	60	1375	SWIR
B11	20	1610	SWIR
B12	20	2190	SWIR

Sentinel misijos pateikia debesų kaukes, kurios gaunamos iš jų jutiklių surinktų daugiaspektrinių duomenų. Debesų kaukės sudaromos pagal algoritmus, kurie analizuoja atspindžio vertes skirtingose spektro juostose, kad nustatytų vaizdo sritis, kuriose gali būti debesų arba debesų šešėlių. Tuomet debesų kaukės taikomos daugiaspektriniams duomenims, kad būtų pašalinti debesų ir šešėlių vaizdų

taškai ir būtų galima tiksliau analizuoti žemės paviršių. Debesų kaukės, kurias suteikia *Sentinel* misijos, ypač naudingos stebint žemės naudojimo, augalinės dangos ir vandens išteklių pokyčius, nes debesys gali užgožti pagrindinį paviršių ir trukdyti tiksliai nustatyti ir analizuoti pokyčius laikui bėgant. Be to, debesų kaukes galima naudoti kartu su kitais *Sentinel* misijų teikiama duomenimis, pavyzdžiui, žemės dangos žemėlapiams ir augmenijos indeksais, kad būtų galima išsamiau suprasti žemės aplinką ir jos pokyčius laikui bėgant.



a)



b)

1.2 pav. Palydovinių vaizdų surinkti duomenys a) S1 vaizdas (Klaipėdos regionas) b) S2 vaizdas (Kauno regionas)

1.2.2. Orto vaizdų gavimas naudojant bepiločius orlaivius

Dronai tampa vis populiarese priemone orto nuotraukoms rinkti, ypač mažose vietovėse, kurias sunku pasiekti tradiciniais metodais [8]. Dronai, kuriuose įrengtos didelės raiškos kameros, dėl savo gebėjimo fiksuoti didelės raiškos vaizdus iš įvairių kampų ir aukščio gali fiksuoti vaizdus, kurių raiška siekia vos kelis centimetrus vienam vaizdo taškui, todėl galima kurti labai detalius orto vaizdus. Dėl to jie yra ideali priemonė tokiose srityse kaip geodeziniai matavimai, kartografavimas ir aplinkos stebėseną, ypač tose, kur ribota prieiga arba sudėtinga orientuotis vietovėje. Be to, dronus galima užprogramuoti skristi iš anksto nustatytais skrydžio maršrutais, o tai gali padėti užtikrinti, kad vaizdai būtų fiksuojami reguliariais intervalais ir esant vienodam apšvietimui, todėl vaizdus lengviau sujungti į vientisą orto vaizdą. Nepaisant techninių ir reguliavimo sunkumų, susijusių su dronų naudojimu, negalima pervertinti jų naudojimo naudos renkant nedidelių teritorijų, kurias sunku pasiekti tradiciniais metodais, orto vaizdus. Toliau tobulėjant dronų technologijoms ir kuriant naujus vaizdų apdorojimo metodus, tikėtina, kad artimiausiais metais dronų naudojimas ortopediniams vaizdams rinkti ir toliau populiarės.

Šiuo metu bepiločiai orlaiviai naudojami meteorologijos, tiksliosios žemdirbystės, laukinės gamtos tyrimų, miškininkystės, žemėtvarkos, infrastruktūros tikrinimo, eismo stebėsenos, ekstremalių epidemijų, stichinių nelaimių valdymo, paieškos ir gelbėjimo laukinėje gamtoje srityse [9].


1.2.3. Vaizdų klasifikavimas pritaikant mašininio mokymosi modelius

Nuotolinis stebėjimas tapo vertinga priemone įvairiose srityse – nuo aplinkos stebėsenos ir gamtos išteklių valdymo iki reagavimo į nelaimes ir miestų planavimo. Tačiau dėl didžiulio nuotolinio stebėjimo platformų generuojamų duomenų kiekio tampa vis sudėtingiau iš šių vaizdų išgauti prasmingą informaciją. Mašininis mokymasis tapo galinga priemone šiam iššūkiui spręsti, nes juo

galima automatiškai klasifikuoti nuotolinio stebėjimo duomenis į įvairias kategorijas pagal jų spektrines charakteristikas [10]. Apmokant mašininio mokymosi algoritmus pagal didelius pažymėtų nuotolinio stebėjimo duomenų rinkinius, galima sukurti modelius, kurie gali dideliu tikslumu klasifikuoti įvairius žemės dangos tipus, pavyzdžiui, miškus, miesto teritorijas ir vandens telkinius. Tai atvėrė naujas galimybes naudoti nuotolinio stebėjimo duomenis įvairioms taikomosioms programoms – nuo žemės naudojimo planavimo ir aplinkos stebėsenos iki reagavimo į nelaimes ir klimato kaitos tyrimų. Toliau tobulėjant mašininio mokymosi metodams, tikėtina, kad nuotolinio stebėjimo duomenų panaudojimo galimybės dar labiau plėsis, todėl nuotolinio stebėjimo duomenys taps vis vertingesne priemone sprendžiant įvairias mūsų planetos problemas.


1.2.3.1. Konvoliucinis neuroninis tinklas

Konvoliucinis neuroninis tinklas (angl. *Convolutional Neural Network*, CNN) yra dirbtinių neuroninių tinklų tipas, dažniausiai naudojamas vaizdų ir vaizdo apdorojimo programose. Jis skirtas automatiškai aptikti ir išmokti požymius įvesties vaizduose, naudojant keletą konvoliucinių sluoksnių, sujungimo sluoksnių ir visiškai sujungtų sluoksnių. Tai leidžia jam labai tiksliai nustatyti vaizdų modelius ir objektus, todėl jis yra galingas įrankis tokioms užduotims, kaip vaizdų klasifikavimas, objektų aptikimas ir segmentavimas, atlikti [11]. Pastaraisiais metais CNN tampa vis populiareni dėl jų gebėjimo pasiekti moderniausių rezultatų sprendžiant įvairias vaizdų apdorojimo užduotis.




1.3 pav. Dažnai naudojamas CNN [11]

Konvoliucinis sluoksnis (angl. *Convolutional Layer*) – vienas iš pagrindinių CNN komponentų yra atsakingas už konkrečių įvesties vaizdų požymių aptikimą ir mokymąsi. Pagrindinė konvoliucinių sluoksnių idėja – mažoms įvesties vaizdo sritims taikyti mokymosi filtrų (dar vadinamų branduoliais arba svoriais) rinkinį, kad būtų sukurtas požymių žemėlapis, kuriame išryškunami svarbūs modeliai ir struktūros. Kiekvienas filtras paprastai yra nedidelė kvadratinė arba stačiakampė verčių matrica, kuri taikydama konvoliucija su atitinkama įvesties vaizdo dalimi ir gaunama viena išvesties vertė, rodanti filtro atitikimo tam tikram įvesties vaizdo regionui laipsnį. Keletą konvoliucinių sluoksnių sudėjus vieną ant kito, CNN gali išmokti vis sudėtingesnių ir abstraktesnių įvesties vaizdo požymių, todėl gali labai tiksliai atpažinti modelius ir objektus.



1.4 pav. Konvoliucinis sluoksnis [12]

Sujungimo sluoksnis (angl. *Pooling Layer*) – dar vienas svarbus CNN komponentas naudojamas konvoliucinių sluoksnių sukurtų požymių žemėlapių erdviniam dydžiui sumažinti. Pagrindinis sujungimo sluoksnių tikslas – iš požymių žemėlapių išskirti svarbiausius požymius ir kartu sumažinti jų dimensiją, o tai padeda sumažinti perteklinį pritaikymą ir padidinti tinklo skaičiavimo efektyvumą. Labiausiai paplitęs grupavimo tipas yra didžiausias (angl. *max*) grupavimas, kai kiekvienas požymių žemėlapis padalijamas į nepersidengiančias stačiakampes sritys ir kiekvienoje srityje imama didžiausia reikšmė, kad būtų gautas naujas, sumažintos atrankos požymių žemėlapis. Panašiam efektui pasiekti galima naudoti ir kitus jungimo tipus, pavyzdžiui, vidutinį jungimą. Po kiekvieno konvoliucinio sluoksnio taikydami sujungimo sluoksnius, CNN gali palapsniui mažinti erdvinį požymių žemėlapių dydį, todėl jie gali išmokti vis sudėtingesnių ir abstraktesnių požymių, o tinklo parametrų skaičius išlieka valdomas. Tačiau svarbu protingai naudoti sujungimo sluoksnius ir suderinti jų mažinimo poveikį su poreikiu išsaugoti svarbią įvesties vaizdų erdvinę informaciją.



1.5 pav. Sujungimo sluoksnio pavyzdys, įgyvendinamas didžiausias sujungimas


Matricai kurios dimensijos yra 4x4 yra pritaikomas sujungimo sluoksnis 2x2 su didžiausia funkcija. Šis sluoksnis dažniausiai nėra didesnis, nei 2x2 dėl savo naikinančio potencialo [11], t.y. panaudojant didesnę apjungimo matricą kyla informacijos praradimo rizika. Sujungimas leidžia sumažinti matricos dydį pritaikant funkciją. Apdorojant vaizdus, šį sluoksnį galima priimti, kaip raiškos mažinimo sluoksnį.

Visiškai sujungtas sluoksnis (angl. *Fully Connected Layer*) – tai sluoksnio tipas, dažniausiai naudojamas neuroniniuose tinkluose, įskaitant CNN, klasifikavimo ar regresijos užduotims atlikti. Skirtingai nuo konvoliucinių ir jungiamųjų sluoksnių, kurie veikia vietines įvesties sritys, visiškai sujungti sluoksniai apdoroja visą įvesties tūrį, kad gautų vieną išvestį. Kiekvienas visiškai sujungto sluoksnio neuronas gauna įvestį iš kiekvieno ankstesnio sluoksnio neuro, o jo išvestis sujungama su kiekvienu kito sluoksnio neuronu. Visiškai sujungto sluoksnio paskirtis – sujungti ankstesnių sluoksnių išmokus požymius į aukšto lygio atvaizdavimą, kuris gali būti naudojamas įvesties

duomenims prognozuoti. CNN pabaigoje pridėjus vieną ar daugiau visiškai sujungtų sluoksnių, tinklas gali išmokti klasifikuoti arba regresuoti pagal išskirtus požymius.

1.2.3.2. Objektų aptikimas

Objektų aptikimas – tai vaizdų klasifikavimo metodas, naudojamas objektams vaizde ar vaizdo įrašė surasti ir klasifikuoti. Objektų aptikimo tikslas – nustatyti kiekvieno vaizde esančio objekto vietą ir tipą, kad būtų galima taikyti, pavyzdžiui, automatiniam vaizdo titravimui, autonominėms transporto priemonėms ir saugumo sistemoms. Objektų aptikimas skiriasi nuo vaizdo klasifikavimo ir semantinio segmentavimo tuo, kad jis ne tik identifikuoja objektus vaizde, bet ir nustato jų buvimo vietą, nubrėždamas aplink juos ribinius laukus. Objektams aptikti naudojamos kelios architektūros, pavyzdžiui Fast R-CNN (angl. *Fast Region-based Convolutional Neural Network*) ir YOLOv5 (angl. *You Only Look Once version 5*). Fast R-CNN yra dviejų etapų objektų aptikimo metodas, kuriuo pirmiausia generuojami regiono pasiūlymai, o tada šie pasiūlymai klasifikuojami kaip objektai arba fonas. YOLOv5 yra vieno etapo objektų aptikimo metodas, kuriuo tiesiogiai numatomos visų vaizdo objektų ribinės dėžės ir klasių tikimybės, atliekant vieną tiesioginį perėjimą per tinklą.




1.6 pav. Objektų aptikimas [13]

Fast R-CNN – tai objektų aptikimo architektūra, sukurta siekiant padidinti R-CNN greitį ir tikslumą. Fast R-CNN veikia dviem etapais. Pirmajame etape architektūra priima įvesties vaizdą ir naudoja CNN, kad sukurtų konvoliucinį požymių žemėlapi. Po to šis požymių žemėlapis perduodamas į regionų siūlymo tinklą (angl. *Region Proposal Network*), kuris siūlo kandidatus į objektų regionus vaizde. Šie siūlomi regionai grindžiami skirtingo dydžio ir proporcijų inkarinių langelių, išdėstyti skirtingose vaizdo vietose, rinkiniu. Regionų siūlymo tinklas apskaičiuoja kiekvieno inkaro langelio tikimybės balą, kad nustatytų, ar jame yra objektas, ar nėra [14].

Antrajame etape architektūra paima kiekvieną pasiūlytą regioną ir atlieka maksimalaus sujungimo operaciją, kad gautų fiksuoto dydžio požymių žemėlapi. Tada šis požymių žemėlapis įvedamas į visiškai sujungtą sluoksnį, kuris atlieka objektų klasifikavimą ir kiekvieno pasiūlyto regiono ribinių dėžučių regresiją. Klasifikavimo tinklas pateikia kiekvienos objekto kategorijos tikimybės balą, o regresijos tinklas pateikia prognozuojamų riboženklių koordinatų poslinkio vertes inkarinių laukų atžvilgiu. Galutinis žingsnis – taikyti nemaksimalų slopinimą, kad būtų pašalinti nereikalingi aptikimai, ir išvesti galutinį objektų aptikimų rinkinį su jiems priskirtomis klasių etiketėmis ir riboženkliais [14].

Fast R-CNN turi keletą pranašumų, palyginti su savo pirmtaku R-CNN. Jis greitesnis, tikslesnis ir

reikalauja mažiau atminties, nes dalijasi konvoliuciniais požymiais skirtingose siūlomose srityse.

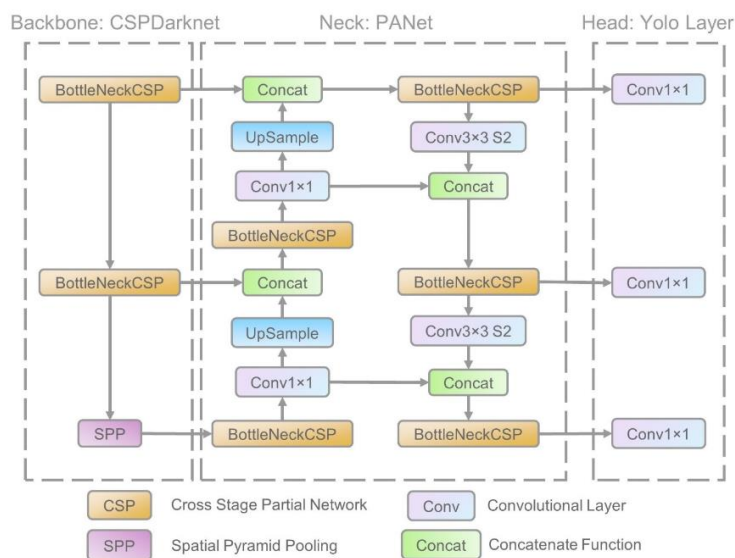


1.7 pav. Fast R-CNN architektūra [14]

YOLOv5 – tai moderni objektų aptikimo realiuoju laiku sistema, kuria galima aptikti objektus vaizduose ir vaizdo įrašuose. YOLOv5 yra vieno etapo detektorius, kuris tiesiogiai numato visų vaizdo objektų ribines dėžes ir klasių tikimybes per vieną tiesioginį perėjimą per tinklą.

Architektūrą sudaro trys dalys – pagrindinis tinklas, kaklo tinklas ir galvos tinklas. Pagrindinis tinklas paprastai yra požymių išskyrimo tinklas, pavyzdžiui, *EfficientNet*, kuris naudojamas požymiams iš įvesties vaizdo išgauti. Kaklo tinklas naudojamas skirtingų mastelių požymiams sujungti ir pagerinti objekto požymių atvaizdavimą. Galvos tinklą sudaro keletas konvoliucinių sluoksnių, kurie generuoja galutines prognozes [15].

YOLOv5 įdiegta keletas ankstesnių versijų patobulinimų, kurie padaro tinklą tikslesniu ir efektyvesniu. Be to, YOLOv5 naudoja hibridinį mokymo metodą, kuriame derinamas ir prižiūrimas, ir neprižiūrimas mokymas, todėl padidėja tinklo tikslumas ir kartu sumažėja mokymui reikalingų paženklintų duomenų kiekis.



1.8 pav. YOLOv5 architektūra. Susideda iš trejų dalių: pagrindinė (angl. *Backbone*) sudaro *CSPDarknet* tinklo architektūra, kaklo (angl. *Neck*) sudaro *PANet* tinklo architektūra ir galvos (angl. *Head*) sudaro *YOLO* sluoksnio architektūra [16].

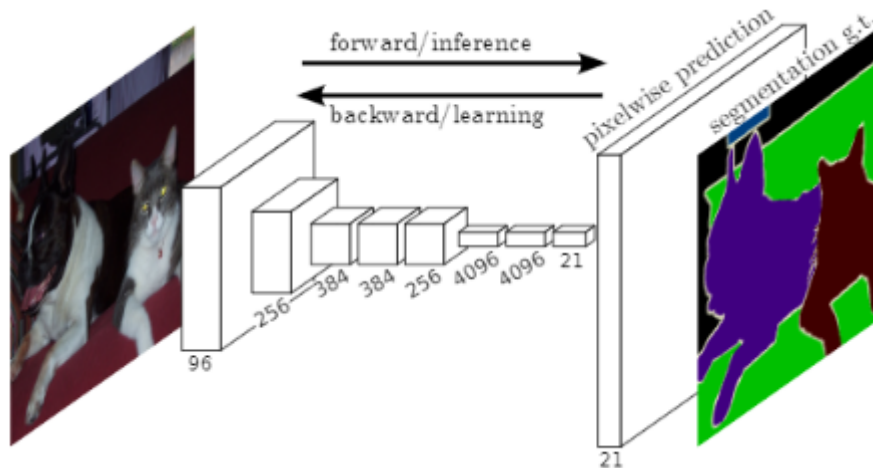
Abi architektūros yra populiarios sprendžiant objektų aptikimo problemas, tačiau YOLOv5 turi tam tikrų pranašumų lyginant su Fast R-CNN, dėl kurių ji yra šiek tiek geresnė. Vienas iš pagrindinių YOLOv5 privalumų – greitis. YOLOv5, kaip vieno etapo objektų aptikimo metodas, gali atlikti objektų aptikimą ir klasifikavimą per vieną perėjimą per tinklą, todėl yra greitesnis už dviejų etapų Fast R-CNN. YOLOv5 taip pat pasižymi didesniu tikslumu nei Fast R-CNN, ypač mažų objektų atveju. Be to, YOLOv5 architektūra yra paprastesnė nei Fast R-CNN, turi mažiau sluoksnių ir parametrų, todėl ją lengviau įdiegti ribotų išteklių įrenginiuose. Dėl savo greičio, tikslumo ir paprastumo YOLOv5 yra geras pasirinkimas objektų aptikimo užduotims spręsti [17].

1.2.3.3. Semantinis segmentavimas

Semantinis segmentavimas – vaizdų klasifikavimo metodas, kai vaizdas padalijamas į kelis segmentus, kurių kiekvienas atitinka tam tikrą objektą ar regioną. Tikslas – kiekvieną vaizdo tašką priskirti konkrečiai kategorijai, pavyzdžiui, žmogus, automobilis ar medis. Yra keletas populiarių architektūrų, naudojamų semantiniam segmentavimui, įskaitant pilnai konvoliucinius tinklus (angl. *Fully Convolutional Networks*, FCN), piramidinį scenos skaidymą (angl. *Pyramid Scene Parsing*, PSP) ir Deeplab architektūrą. Šiose architektūrose, kaip pagrindas naudojamas CNN, kurio populiariausi variantai yra ResNet-50 (angl. *Residual Network with 50 layers*) ir ResNet-101 (angl. *Residual Network with 101 layers*). FCN yra paprasta, bet veiksminga architektūra, kuri gali pateikti tankias prognozes kiekvienam vaizdo taškui. PSP naudoja piramidžių telkimo modulius, kad užfiksuotų visuotinį kontekstą, ir pasiekė geriausias rezultatus keliuose duomenų rinkiniuose. Architektūra Deeplab naudoja išplėstinę konvoliuciją, kad padidintų tinklo priėmimo lauką, ir įrodė, kad yra labai veiksminga sprendžiant semantinio segmentavimo užduotis.

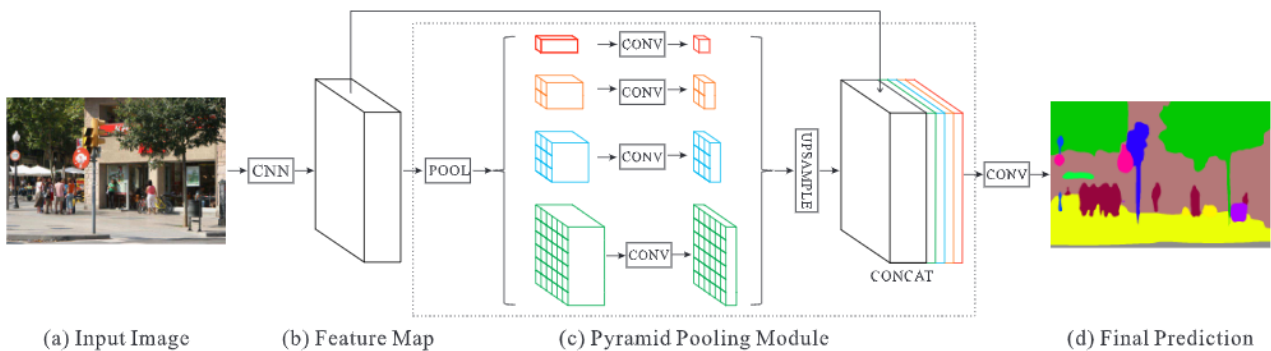
Semantinėje segmentacijoje kiekvienam vaizdo taškui priskiriama viena iš anksto nustatytų klasių. Šis metodas naudojamas fiksuotam klasių kiekiui klasifikuoti, pavyzdžiui, miškui ir ne miškui palydovinėje nuotraukoje [18]. Šiuo atveju kiekvienas vaizdo taškas paženklinamas, kaip „miškas“ arba „ne miškas“, sukuriant dvejetainę kaukę, kurią galima naudoti mišku apaugusios teritorijos vietai ir apimčiai nustatyti. Semantinis segmentavimas gali būti taikomas ir RGB, ir pilkiesiems vaizdams, kai kiekvienas vaizdo taškas klasifikuojamas pagal jo spalvą arba intensyvumo reikšmes. Šis metodas plačiai taikomas įvairiose srityse, pavyzdžiui, medicininių vaizdų analizėje, autonominėse transporto priemonėse ir robotikoje [18].

Pilnai konvoliuciniai tinklai (FCN) – tai semantinio segmentavimo architektūros tipas, kurio išvestis yra vaizdas, turintis tokius pačius erdvinis matmenis kaip ir įvestis. FCN architektūroje naudojamas CNN, paprastai turintis ResNet-50 arba ResNet-101 architektūros pagrindą, kuriuose pašalinami visiškai sujungti sluoksniai, pakeičiant juos konvoliuciniais sluoksniais. Paskutinis tinklo sluoksnis sukuria išvesties matricą, kurioje kiekvienas vaizdo taškas klasifikuojamas pagal klasę, kuriai jis priklauso. Norint padidinti išvesties vaizdą iki įvesties vaizdo dydžio, FCN naudoja transponuotas konvoliucijas, dar vadinamas dekonvoliucijomis (angl. *Deconvolution*). Mokymo metu tinklas optimizuojamas taip, kad būtų sumažinti kryžminės entropijos nuostoliai tarp prognozuojamos išvesties ir pagrindinės tiesos (angl. *Ground truth*) klasių. Mokydamasis iš duomenų rinkinio su pažymėtais vaizdais, FCN gali išmokti segmentuoti vaizdą dominančius objektus, pavyzdžiui, pastatus, kelius ir medžius. FCN išvestis gali klasifikuoti fiksuotą klasių skaičių, pavyzdžiui, jei norime vaizdą klasifikuoti į dvi klases: „miškas“ ir „ne miškas“, išvestis bus vaizdas, kuriame bus pateiktos tik šios dvi klasės.



1.9 pav. Pilnai konvoliucinis tinklas (FCN), pritaikytas semantinei segmentacijai [19]

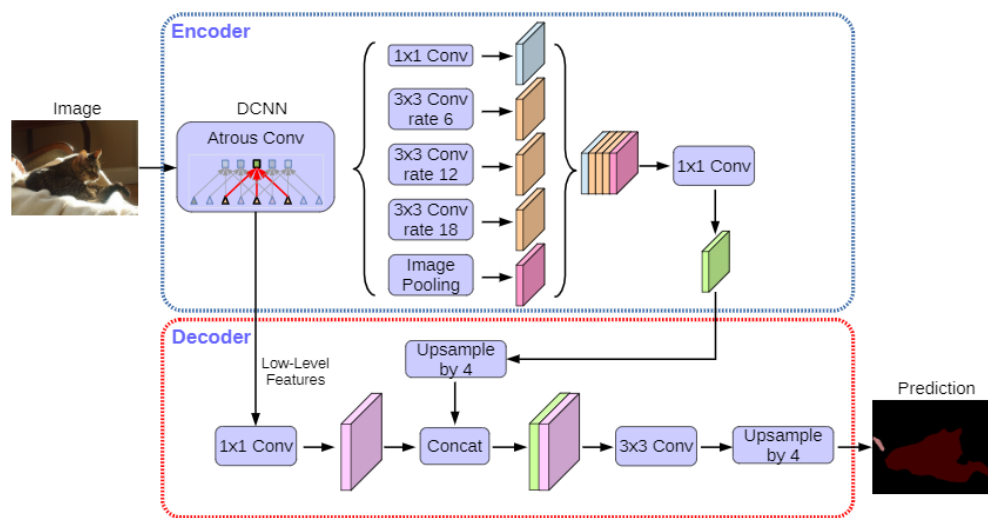
Piramidinis scenos skaidymas (PSP) – tai semantinio segmentavimo architektūra, kurioje naudojami kelių mastelių požymių žemėlapiai, siekiant padidinti tinklo gebėjimą atpažinti skirtingo mastelio objektus. PSP tai pasiekama pirmiausia perduodant vaizdą per konvoliucinį neuroninį tinklą, pavyzdžiui, ResNet-50 arba ResNet-101, kad būtų išgauti požymių žemėlapiai. Tada šie požymių žemėlapiai apdorojami per piramidės telkimo modulį, kuris juos suskirsto į kelis mastelius, ir kiekvienas mastelis maksimaliai telkiamas, kad būtų gautas fiksuoto dydžio atvaizdas. Fiksuoto dydžio atvaizdai sujungiami su originaliais požymių žemėlapiams, kad būtų gauti požymių žemėlapiai, kuriuose kontekstas užfiksuotas keliais masteliais. Galiausiai sujungti požymių žemėlapiai apdorojami per kelis konvoliucinius ir didinančius sluoksnius, kad būtų gautas galutinis segmentavimo žemėlapis [20].



1.10 pav. PSP tinklo architektūra. Turint įvesties vaizdą (a), pirmiausia CNN pagalba gaunamas paskutinio konvoliucinio sluoksnio požymių žemėlapis (b), tada taikomas piramidės skaidymo modulis, kad būtų galima surinkti įvairių mažesnių vaizdus, po to seka didinamasis sluoksnis ir jungiamasis sluoksnis, kad būtų suformuotas galutinis požymių atvaizdas, kuriame pateikiama tiek vietinio, tiek visuotinio konteksto informacija (c). Galiausiai ši reprezentacija perduodama į konvoliucijos sluoksnį, kad būtų gauta galutinė vieno taško prognozė (d) [20].

Deeplabv3+ yra moderni architektūra, naudojama semantiniam segmentavimui. Architektūra pagrįsta modifikuota *Xception* neuroninio tinklo versija, kuri naudojama kaip pagrindas požymiams išgauti. Tinkle naudojama išplėstinė konvoliucija, kuri leidžia padidinti priimamąjį lauką neprarandant skiriamosios gebos. Architektūra taip pat apima visuotinio sujungimo modulį, kuris padeda užfiksuoti skirtingo mastelio erdvinę informaciją. Galiausiai pridamas dekoderio modulis, kuris segmentavimo žemėlapi patikslina taškų lygmeniu [21]. Deeplabv3+ pasiekė gerus rezultatus keliuose

lyginamuosiuose duomenų rinkiniuose, todėl jis tapo populiariu pasirinkimu įvairioms semantinio segmentavimo programoms.



1.11 pav. Deeplabv3+ architektūra. Kodavimo modulis koduoja daugialypę kontekstinę informaciją, taikydamas kelių mastelių išplėstinę konvoliuciją, o paprastas, bet veiksmingas dekoderio modulis patikslina segmentavimo rezultatus pagal objektų ribas [21].

FCN, PSP ir DeepLab yra populiarios kompiuterinės regos srityje naudojamos semantinio segmentavimo architektūros. Nors visų trijų modelių tikslas yra panašus – tiksliai segmentuoti vaizdus, jie skiriasi savo metodu ir našumu.

FCN yra architektūra, kurioje tradicinių CNN visiškai sujungti sluoksniai pakeičiami konvoliuciniais sluoksniais, todėl galima atlikti segmentavimą pagal vaizdo taškus. FCN yra palyginti paprasta architektūra, kuri gali užtikrinti tikslų segmentavimą ir kartu yra skaičiavimo požiūriu efektyvi.

PSP tinklas, naudoja piramidinį telkimo modulį, kad užfiksuotų kelių mastelių kontekstinę informaciją, kuri vėliau sujungiama, kad būtų sukurtas galutinis segmentavimas. Tai leidžia sukurti patikimesnius segmentus, kuriuose galima geriau užfiksuoti smulkias detales ir atsižvelgti į skirtingus objektų dydžius.

Kita vertus, DeepLab naudoja išplėstines konvoliucijas, kad padidintų tinklo priimamąjį lauką ir galėtų užfiksuoti daugiau visuotinės konteksto informacijos. Be to, DeepLab įdiegtas sąlyginio atsitiktinio lauko (angl. *Conditional Random Field*) modulis, skirtas segmentavimui patikslinti ir triukšmui sumažinti.

Įrodyta, kad DeepLab tikslumo požiūriu lenkia tiek FCN, tiek PSP keliuose lyginamuosiuose duomenų rinkiniuose [21]. Tačiau FCN ir PSP dėl paprastesnės architektūros gali pasiekti greitesnį išvadų darymo laiką [19], [20].

1.2.3.4. Vaizdų klasifikavimo metrikos

Teisingas teigiamas (angl. *True positive*, TP), neteisingas teigiamas (angl. *False positive*, FP), teisingas neigiamas (angl. *True negative*, TN) ir neteisingas neigiamas (angl. *False negative*, FN) rezultatai – tai statistinėje analizėje ir mašiniame mokymesi dažniausiai vartojami terminai, skirti prognozuojančio modelio ar klasifikavimo sistemos veikimui įvertinti. Klases trumpai galima apibrėžti taip:

- TP – modelis teisingai identifikuoja klasės egzistavimą;
- FP – modelis klaidingai identifikuoja klasės egzistavimą;
- TN – modelis teisingai identifikuoja klasės nebuvimą;
- FN – modelis klaidingai identifikuoja klasės nebuvimą.

Mašininio mokymosi srityje tikslumas (angl. *Precision*, P) ir atpažinimas (angl. *Recall*, R) yra du svarbūs rodikliai, naudojami klasifikavimo sistemos našumui įvertinti. Tikslumas įvardijamas, kaip teisingų teigiamų aptikimų dalis iš visų sistemos teigiamų aptikimų. Ji matuoja sistemos tikslumą nustatant teisingus objektus. Didelis tikslumas rodo, kad sistema retai klaidingai identifikuoja objektus. Kita vertus, atpažinimas nurodo teisingų teigiamų aptikimų dalį iš visų faktiškai teigiamų objektų duomenų rinkinyje. Jis parodo, kaip gerai sistema geba aptikti visus objektus. Didelis atpažinimas rodo, kad sistema aptinka didžiąją dalį duomenų rinkinio objektų. Nustatant objektus, tikslumas ir atpažinimas naudojami kartu, siekiant nustatyti bendrą sistemos našumą. Sistema, turinti didelį tikslumą, bet mažą atpažinimą, gali nepastebėti kai kurių objektų, o sistema, turinti didelį atpažinimą, bet mažą tikslumą, gali klaidingai nustatyti daug objektų [22].

Žemiau pateikiama tikslumo formulė:

$$P = \frac{TP}{TP + FP}; \quad (1)$$

čia P – tikslumas (angl. *Precision*);

TP – teisingas teigiamas klasifikavimų kiekis;

FP – neteisingas teigiamas klasifikavimų kiekis.

Žemiau pateikiama atpažinimo formulė:

$$R = \frac{TP}{TP + FN}; \quad (2)$$

čia R – atpažinimas (angl. *Recall*);

TP – teisingas teigiamas klasifikavimų kiekis;

FN – neteisingas neigiamas klasifikavimų kiekis;

Taškų tikslumas (angl. *Pixel Accuracy*, PA) – tai segmentavimo modelio tikslumo matas apdorojant vaizdus. Jis apskaičiuoja modelio teisingai suklasifikuotų vaizdo taškų procentinę dalį ir palyginą ją su pagrindine tiesa. Taškų tikslumas atsižvelgia į kiekvieną vaizdo tašką ir kiekvienam jų suteikia vienodą reikšmę, neatsižvelgiant į jų vietą. Metrika apskaičiuojama dalinant teisingai klasifikuotus vaizdo taškus iš visų vaizdo taškų. Šis vertinimas turi trukumą, jog vienai klasei dominuojant vaizde, gaunami rezultatai gali būti aukšti, nors modelis neteisingai klasifikavo vaizdą [23].

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

čia PA – taškų tikslumas (angl. *Pixel Accuracy*);

TP – teisingas teigiamas taškų klasifikavimo kiekis;

TN – teisingas neigiamas taškų klasifikavimo kiekis;

FP – neteisingas teigiamas taškų klasifikavimo kiekis;

FN – neteisingas neigiamas taškų klasifikavimo kiekis.

Sankirtos koeficientas (angl. *Intersection over Union*, IoU) – tai metrika dažnai naudojama objektų aptikimo ir semantinės segmentacijos užduotyse. Koeficientas matuoja prognozuojamo ribinio lauko arba segmentavimo kaukės ir pagrindinės tiesos sutapimą. Sankirtos koeficientas apskaičiuojamas imant klasifikuoto ir teisingo regiono sankirtą ir padalinant ją iš klasifikuoto ir teisingo regiono sąjungos. Gauta reikšmė yra dviejų regionų sutapimo matas, o didesnė reikšmė rodo didesnę sutapimą ir didesnę tikslumą.

$$IoU = \frac{P \cap A}{P \cup A} \quad (4)$$

čia IoU – sankirtos koeficientas (angl. *Intersection over Union*);

P – klasifikuoti vaizdo taškai;

A – teisingi vaizdo taškai.

IoU yra geresnis tikslumo matas nei PA atliekant semantinio segmentavimo užduotis, nes juo vertinamas numatytų ir pagrindinių segmentavimo kaukių sutapimas, atsižvelgiant į objektų formą ir padėtį. Semantinio segmentavimo metu kiekvienam vaizdo taškui priskiriama etiketė, nurodanti, kokiam objektui ar klasei jis priklauso. PA vertinama teisingai pažymėtų vaizdo taškų dalis, neatsižvelgiant į objektų formą ir padėtį. Tačiau semantinio segmentavimo atveju objektų forma ir padėtis yra svarbūs veiksniai, lemiantys modelio tikslumą. IoU įvertina prognozuojamos segmentavimo kaukės ir pagrindinės tiesos kaukės panašumą, apskaičiuodamas dviejų kaukių susikirtimo ir sąjungos santykį, suteikdamas didesnę svorį teisingai segmentuotiems regionams. IoU yra geresnė vertinimo metrika semantinio segmentavimo užduotims, nes ji matuoja prognozuojamos ir pagrindinės tiesos segmentavimo kaukių panašumą, tiksliau atsižvelgiant į objektų formą ir padėtį.

1.2.3.5. Duomenų rinkiniai

Modelio apmokymui reikia sudaryto duomenų rinkinio. Duomenų rinkinys susideda iš vaizdo ir kaukės. Kaukės gali būti aprašytos RGB spektrine juosta arba viena spektrine juosta. Vienos atveju gali būti apribotas didžiausias galimas identifikavimo klasių skaičius (pvz. iki 254). Duomenų rinkinys sudaromas bent iš dviejų klasių, pavyzdžiui: „medis“ ir „ne medis“. Iš vienos klasės sudaryti negalima, nes modelis negalės apskaičiuoti identifikacijos tikslumo. Kai kurie duomenų rinkiniai palaiko ir *void* tipo klases (vaizdo taškai kurie yra pažymimi atskirai ir išskiriami kaip neturintys informacijos, dažniausiai žymimi 0), kurios leidžia modeliui pateikti nepilnai klasifikuotas kaukės [24].

Duomenų rinkinį galima sudaryti savo su visa struktūra ir įgyvendinimu arba pritaikyti viena iš egzistuojančių populiarių duomenų rinkinių kurių pagrindinis privalumas – įgyvendinimas populiariuose vaizdų segmentaciją palaikančiuose karkasuose.

Populiarūs duomenų rinkiniai:

ADE20k – pasižymi elementaria aplankų struktūra (vaizdas, kaukė), kaukės yra sudaromos iš vienos spektrinės juostos rezervuojant 0, kaip *void* tipo klasę;

Pascal VOC – pasižymi sudėtinga aplankų struktūra (skirtas ir semantinei segmentacijai ir objektų

aptikimui), kaukės yra sudaromos iš RGB vaizdų, vaizdams priskiriant atitinkama klasę;

Cityscapes – pasižymi elementaria aplankų struktūra, kaukės yra sudaromos iš RGB vaizdų, vaizdui priskiriant atitinkamą klasę.

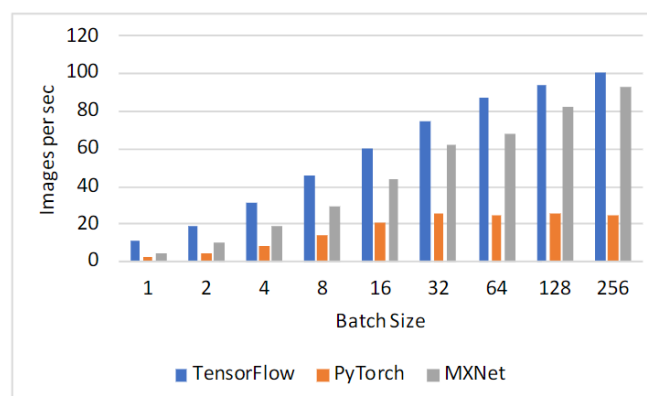
Duomenų rinkinys *ADE20k* turi paprasčiausia struktūra, rinkinys taip pat pasižymi anotacijos paprastumu, todėl jis puikiai tinka, kai reikia identifikuoti tik 2 klases.

1.2.3.6. Vaizdų identifikacijos karkasai

Vertinami trys populiarūs *python* programavimo kalbos karkasai palaikantys vaizdų segmentacijos modelius – *mxnet*, *tensorflow*, *pytorch*.

Pagrindiniai vertinimų kriterijai, renkantis giliojo mokymosi karkasą, yra veikimo greitis, atminties valdymas, duomenų rinkinių palaikymas ir modelių įmontuotas palaikymas. Veikimo greitis pažymimas atliekant sudėtingus modelio mokymo uždavinius, pavyzdžiui, paruošiant semantinio segmentavimo modelį. Atminties valdymas apibrėžiamas atminties našumų, atliekant modelio mokymą. Duomenų rinkinių palaikymas pažymimas kiekiu skirtingų duomenų rinkinių kuriuos karkasas iš karto gali apdoroti neatlikdamas papildomų duomenų rinkinių aprašymų programiškai. Modelių įmontuotas palaikymas pažymimas skirtingų modelių palaikymų nereikalaujant papildomo modelių sukūrimo programiniu būdu.

Atliktuose tyrimuose geriausiai greitis vertinamas *tensorflow* karkaso, toliau *mxnet* ir *pytorch* [25].



1.12 pav. Vaizdų apdorojimo greitis pagal pateikiamą imtį [25]

Našiausias karkasas atminties valdymui yra *mxnet*, kuris panaudoja grafų optimizacijos funkcijas, jog sutaupyti atminties [25].

Visi trys aprašyti modeliai pasižymi aprašytų duomenų rinkinių palaikymu.

Modelių įmontuotas palaikymas ir jų modifikavimas, naujų modelių aprašymas. Karkasas *mxnet* pasižymi atvirumu, t. y. modelius galima lengvai modifikuoti, jie nėra paslėpti giliai kode ir neprieinami [25]. Karkasas *tensorflow* pasižymi didele modelių kūrimo įvairove ir modifikavimu [26].

1.2.4. Palydovinių vaizdų panaudojimas

Palydovinių vaizdų prieinamumas leidžia mokslininkams atlikti svarbius tyrimus ir rinkti informaciją, išvengiant lauko tyrimo. Įvairios nuotolinio aptikimo technologijos leidžia mokslininkams atlikti

tyrimus nacionaliniu, globaliu ir regioniniu mastu [27]. Tyrimai gali būti įvairaus pobūdžio. Populiarios tyrimų kryptis – miškingumo pokyčiai [28]–[32], pasėlių stebėjimas [33], [34], potvynių stebėjimas [35], [36].

1.2.4.1. Miškų identifikavimas

Vienas dažniausių nuotolinio aptikimo pritaikymų yra miškų identifikavimas. Miškų išskyrimas gali būti vykdomas taikant paprastą dvejetainę klasifikaciją (miškas / ne miškas) [31], [32], [37] arba taikomas klasifikuojant skirtingus medžių tipus (ąžuolas / beržas / pušis) [29], [32]. Atlikus tokį identifikavimą, toliau galima gauti svarbios informacijos apie miškingumo pasikeitimus per tam tikrą laiko tarpą [31]. Nuotoliniai stebėjimo būdai vis plačiau naudojami nelegalių miškų kirtimų prevencijai [28]. Kadangi neįmanoma fiziškai visą laiką prižiūrėti miškingų teritorijų, ypač tų, kurios yra sunkiai pasiekiamos, šį darbą labai palengvina nuotolinis stebėjimas. Vienas iš pagrindinių privalumų, kuriuos šiuo atžvilgiu suteikia toks stebėjimo būdas, yra fiksavimo laikotarpis. Dėl pakankamai dažno pakartotinio fiksavimo laikotarpio (2 – 4 sav. dažniausiai), šis stebėjimo būdas leidžia užtikrinti nuolatinį stebėjimą milžiniškoms teritorijoms, tai būtų neįmanoma taikant lauko stebėjimo metodus. Miškų identifikavimas, taikant nuotolinius metodus, dažniausiai palydovus, turi ir savo trūkumų, viena pagrindinių problemų – oro sąlygos, kurios gali būti neprognozuojamos, ypač teritorijose, kurios pasižymi ekstremaliu klimatu [28]. Prastos oro sąlygos pasižymi debesuotumu, kuris gali neleisti palydovui gauti prasmingos informacijos. Šią problemą galima spręsti naudojant palydovus, kurie nuotraukas fiksuoja naudojant radarus. Radarai leidžia apeiti debesuotumą, tačiau dažniausiai pasižymi prastesne raiška dėl savo veikimo dažnio juostos [32]. *Sentinel* šeimos palydovai yra skirti nuotoliniam žemės paviršiaus stebėjimui. S1 palydovo vaizdai gaunami su SAR (angl. *Synthetic Aperture Radar*) tipo duomenimis. Palydovo privalumas – radaro gaunami duomenys, kurių neveikia gamtos sąlygos [38]. S2 palydovo vaizdai yra pateikiami su 12 skirtingų spektrinių juostų įskaitant infraraudonųjų spindulių juostas. Šis palydovas pasižymi dideliu kiekiu prieinamų spektrinių juostų, bei aušktu tikslumu [30].

Abu palydovai pasižymi dažnu pakartotinio fiksavimo intervalu (apie 5 dienos) [38]. *Sentinel* palydovų surenkama informaciją yra prieinama viešai [38]. Tai suteikia puikias galimybes palydovus naudoti nuotolinio stebėjimo projektams atlikti. Vienas populiariausių šių palydovų pritaikymų yra miškų identifikavimas ir jų pokyčių stebėjimas [29], [30], [32], [37], [38].

1.2.4.2. Miškų poligonų duomenys

OpenStreetMap (OSM) – tai nemokamas atvirojo kodo pasaulio žemėlapis, kurį kuria ir prižiūri pasaulinė savanorių bendruomenė. Vienas iš OSM panaudojimo miškų plotų poligonams gauti privalumų yra tas, kad jis nuolat atnaujinamas naujais duomenimis iš įvairių šaltinių, įskaitant palydovines nuotraukas, orto nuotraukas ir kartografavimo darbus vietoje [39]. Tai reiškia, kad OSM duomenys dažnai yra aktualesni ir tikslesni nei kitų žemėlapių duomenų šaltinių duomenys. Be to, OSM yra labai detalus, jame galima rasti daugybę elementų, įskaitant kelius, pastatus ir žemės dangos tipus, pavyzdžiui, miškus. Dėl to OSM yra vertingas šaltinis informacijai apie miškų buvimo vietą ir plotą gauti. Kadangi OSM yra atvirojo kodo, duomenys yra laisvai prieinami visiems norintiems jais naudotis, todėl tai yra prieinama galimybė gauti miškų poligonus.

Pagrindinis OSM trūkumas – kokybė. Nors OSM aprėpia visą pasaulio plotą, jis ne visada yra išsamus ir nuoseklus. Kai kurios vietovės gali būti kartografuotos tankiau nei kitos, todėl duomenys gali skirtis.

Aukštos kokybės sluoksniai (angl. *High Resolution Layers*, HRL) – tai, *Copernicus Pan-European*

programos, didelės skiriamosios gebos geografiniai duomenys, kuriuose pateikiama išsami informacija apie Europos miškus. Duomenys renkami naudojant nuotolinio stebėjimo metodus, įskaitant palydovines nuotraukas ir LiDAR (angl. *Light Detection and Ranging*) technologijas. Didelė duomenų skiriamoji geba leidžia atlikti tikslus miškų matavimus, įskaitant medžių dydį, formą ir pasiskirstymą. Be to, duomenys renkami didelėje teritorijoje, apimančioje visą Europos žemyną, todėl galima atlikti išsamius ir nuoseklius miškų matavimus. Šio sprendimo tikslumą dar labiau didina pažangių algoritmų, skirtų ištaisyti bet kokias duomenų paklaidas, naudojimas. Dėl didelės skiriamosios gebos duomenų ir pažangių algoritmų naudojimo tai yra labai tiksli Europos miškų matavimo priemonė [7]. Pagrindinis šio sprendimo trūkumas – paskutiniai matavimai išleisti 2018 metais. Taip pat nėra garantuojami kitų metų išleidimai (pagal šio projekto ribojimus).

1.2.5. Dronų panaudojimas

Dronai arba bepiločiai orlaiviai, gali būti aprūpinti įvairiais jutikliais, kuriais galima rinkti duomenis apie žemės paviršių. Jie gali būti naudojami nuotoliniam stebėjimui įvairiais būdais.

Šiuo metu bepiločiai orlaiviai naudojami meteorologijos, tiksliosios žemdirbystės, gamtos tyrimų, miškininkystės, žemėtvarkos, infrastruktūros tikrinimo, eismo stebėsenos, ekstremalių epidemijų, stichinių nelaimių valdymo, paieškos ir gelbėjimo laukinėje gamtoje srityse [9].

1.2.5.1. Riedulių klasifikavimas

Riedulių aptikimas naudojant nuotolinį stebėjimą yra naudingas dėl įvairių priežasčių. Pavyzdžiui, tai gali padėti įvertinti potvynių ar erozijos pavojų vietovėje, o tai svarbu bendruomenių ir infrastruktūros saugumui. Taip pat gali būti naudojama planuojant infrastruktūros, pavyzdžiui, tiltų ir užtvankų, statybą, užtikrinant, kad jie būtų projektuojami ir statomi atsižvelgiant į vietovės geologiją ir kuo labiau sumažinant galimą poveikį aplinkai. Apskritai, riedulių aptikimas naudojant nuotolinį stebėjimą yra vertinga priemonė, padedanti suprasti ir valdyti aplinką, taip pat skatinti bendruomenių ir infrastruktūros saugumą ir gerovę.

Objektams upėje klasifikuoti puikiai tinka dronai dėl savo pakankamai žemos kainos ir puikios raiškos (iki 10 cm per vieną vaizdo tašką) [40]. Dronai, taip pat, kaip ir palydovai gali būti aprūpinami įvairiais sensoriais. Dažniausiai naudojami sensoriai – LiDAR [41], radaro [42] ir spektrometro [43].

1.3. Atrinkti metodai ir technologijos

1.3.1. Miškingos teritorijos klasifikavimas

1.3.1.1. Palydoviniai vaizdai

Palydovinės nuotraukos yra puiki priemonė miškų plotams klasifikuoti dėl plačios aprėpties ir lengvo prieinamumo. Palyginti su dronais, kurių veikimo nuotolis ribotas ir kuriems būtinas fizinis buvimas, palydoviniai vaizdai gali aprėpti didelius plotus ir jiems netrukdo fizinės kliūtys. Palydoviniai vaizdai pasižymi trumpu pakartotinio fiksavimo intervalu, dėl šios priežasties dideliu dažniu galima stebėti miško dangos pokyčius ir greitai nustatyti miškų naikinimo ar degradacijos požymius. Be to, palydovinius vaizdus galima apdoroti įvairiais algoritmais ir metodais, kad būtų galima išgauti reikšmingą informaciją apie miško dangą, pavyzdžiui, nustatyti miškų rūšis. Dėl lengvos prieigos ir plačios palydovinių vaizdų aprėpties jie yra ideali miškų klasifikavimo ir stebėsenos priemonė.

1.3.1.2. Klasifikavimas

Apsvarsčius įvairias galimybes, nuspręsta miško klasifikavimui naudoti semantinį segmentavimą ir taikyti FCN, PSP ir DeepLab modelius. Nors FCN leidžia greitai apmokyti papildomus modelius, nustatyta, kad DeepLab gali užtikrinti didžiausią tikslumą. Taip pat buvo apvarstyta PSP modelis, kuris prireikus gali būti naudojamas kaip alternatyva FCN ir DeepLab modeliams.

1.3.2. Upės riedulių klasifikavimas

1.3.2.1. Dronų taikymas

Dronų vaizdai buvo pasirinkti, kaip tinkamiausias metodas rieduliams upėse nustatyti. Dronais galima pasiekti sunkiai ištiriamas vietas, kurios gali būti neprieinamos žmonėms, ir gauti aukštos kokybės upės vaizdus, kurių vieno vaizdo taško raiška siekia iki 10 cm. Toks didelis detalumas leidžia tiksliai identifikuoti ir klasifikuoti riedulius. Be to, dronų vaizdus galima rinkti greitai ir efektyviai, todėl galima dažnai stebėti ir vertinti upės aplinkos pokyčius.

1.3.2.2. Klasifikavimas

Objektų aptikimas buvo pasirinktas, kaip tinkamiausias klasifikavimo būdas rieduliams aptikti naudojant dronų vaizdus. Objektų aptikimas leidžia tiksliai identifikuoti ir lokalizuoti objektus vaizde, o tai idealiai tinka rieduliams upėse identifikuoti. Naudodami objektų aptikimą galime ne tik klasifikuoti riedulius, bet ir nustatyti jų buvimo vietą dronu užfiksuotose orto vaizduose. Tai leidžia mums tiksliai sudaryti riedulių pasiskirstymo ir gausos upėje žemėlapi, o tai labai svarbu įvairioms taikomosioms programoms, pavyzdžiui, hidrauliniam modeliavimui ir upių valdymui.

1.3.3. Taikytinas duomenų rinkinys

Atsižvelgus į galimybę sukurti arba panaudoti jau esamus duomenų rinkinius juos modifikuojant, labiausiai tinkamų duomenų rinkiniu nustatytas *Ade20k* duomenų rinkinys. Šis rinkinys pasižymi elementaria struktūra ir puikiai tinka atlikti „miškas“ ir „ne miškas“ dvejų klasių atrinkimą.

Objektų aptikimui pasirinktas *Pascal VOC* duomenų rinkinys. Šis duomenų rinkinys yra vienas populiariausių tarp objekto aptikimo uždavinių, todėl daugelis karkasų jį iškart palaiko.

1.3.4. Tinkamas vaizdų identifikacijos karkasas

Įvertinus galimus vaizdų karkasus tinkamiausias nustatytas *mxnet* karkasas. Šis karkasas pasižymi puikiu atminties naudojimu ir dideliu lankstumu [44]. Geras atminties naudojimas leis pritaikyti didesnius modelius.

1.4. Egzistuojančių rinkoje sistemų vertinimas

Kai kurie nuotolinio stebėjimo priemonių, naudojamų miško plotų stebėsenai, pavyzdžiai:

- *Global Forest Watch* – tai internetinė platforma, kuri naudoja palydovines nuotraukas ir kitus duomenis, kad beveik realiu laiku pateiktų informaciją apie miškų būklę visame pasaulyje. Naudotojai gali stebėti miškų dangos pokyčius, taip pat nustatyti teritorijas, kurioms gresia miškų naikinimo ar nykimo pavojus.
- *Forest Change Detection and Analysis Tool* – tai priemonė, kuri naudoja palydovinius vaizdus miškų ploto pokyčiams per tam tikrą laiką stebėti. Naudotojai gali nustatyti teritorijas, kuriose

įvyko miško dangos pokyčiai, ir kiekybiškai įvertinti šių pokyčių mastą.

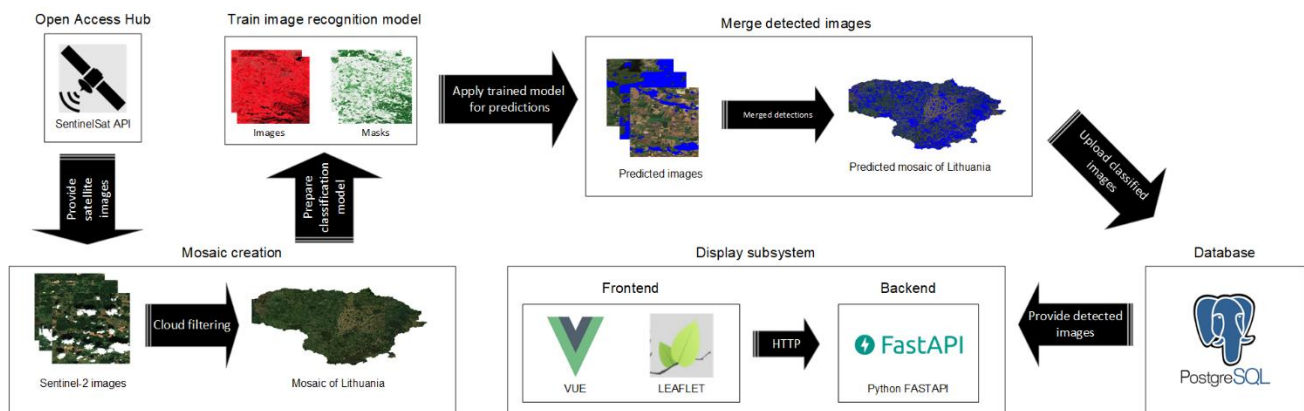
- *Land Cover Atlas* – tai internetinė platforma, kurioje pateikiama išsami informacija apie Europos žemės dangą, įskaitant miškus. Joje naudojami palydovinių vaizdų ir kitų duomenų šaltinių deriniai, kad būtų galima gauti informacijos apie miškų vietą, plotą ir savybes regione.

Tačiau visos šios sistemos neturi nuolatinio intervalo miškingos teritorijos matavimo ir vizualizavimo. Šiose sistemose yra pateikiamas paskutinis matavimas, todėl pokyčius sekti tampa ganėtinai nepatogu. Tai pat daugelyje sistemų modeliai yra paruošiami didelėms teritorijoms, todėl jų tikslumas mažesnėms apimtims nukenčia. Specializuotas modelis leistu tiksliau įvertinti pokyčius.

2. Projektinė dalis

2.1. Konceptas

Pagrindinis sistemos koncepcijos aspektas yra jos padalijimas į dvi atskiras dalis, kurių kiekvienos paskirtis – supaprastinti lauko tyrimus naudojant nuotolinio stebėjimo programas. Pirmoje sistemos dalyje naudojami *Sentinel* palydovai duomenims apie šalį ir jos miškus rinkti ir klasifikuoti. Antroji sistemos dalis apima iš Lietuvos Energetikos Instituto (LEI) dronų gaunamus vaizdus, kad būtų galima klasifikuoti riedulius upėse. Padalijus sistemą į dvi atskiras dalis, tyrimų procesą galima optimizuoti naudojant nuotolinio stebėjimo metodus, o tai padės efektyviau rinkti ir analizuoti duomenis. Žemiau (žr. 2.1 pav. ir 2.2 pav.) pateikiami sistemos dalių konceptai.

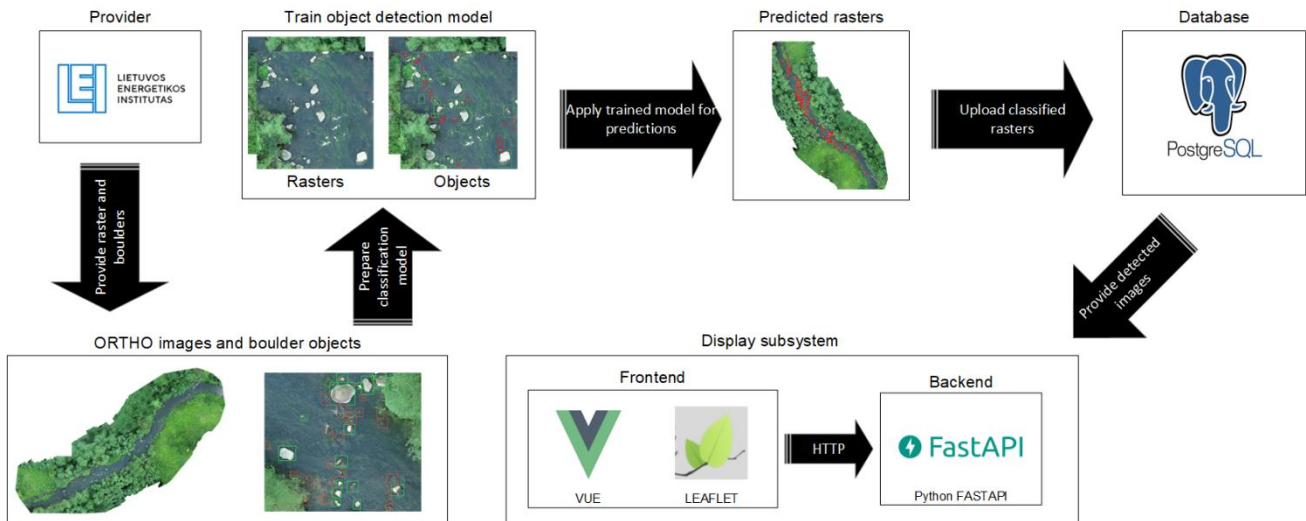


2.1 pav. Miškingumo klasifikavimo sistemos dalis

Pradinis planuojamas miškų klasifikavimo posistemės veikimas:

- Sistema siunčia palydovinius vaizdus iš *Sentinel* vaizdų tiekėjo (pvz. iš *OpenAccessHub*);
- Atliekant vaizdų apdorojimą ir mozaikos sudarymą yra filtruojami vaizdai su debesuotumu;
- Sudaromas semantinės segmentacijos duomenų rinkinys ir panaudojus rinkinį apmokomas klasifikavimo modelis;
- Atliekamas visos Lietuvos teritorijos miškingumo klasifikavimas taikant paruoštą klasifikavimo modelį;
- Atlikus klasifikavimą sudaroma nauja Lietuvos mozaiką su klasifikuotais miškais;
- Mozaikos patalpinamos duomenų bazėje;
- Atvaizdavimo sistema naudojami duomenų bazėje patalpintais vaizdais ir juos pateikia per WEB sąsają.

Sistema turėtų gebėti vieną kartą per metus surinkti vaizdus ir juos klasifikuoti.



2.2 pav. Upės riedulių klasifikavimo sistemos dalis

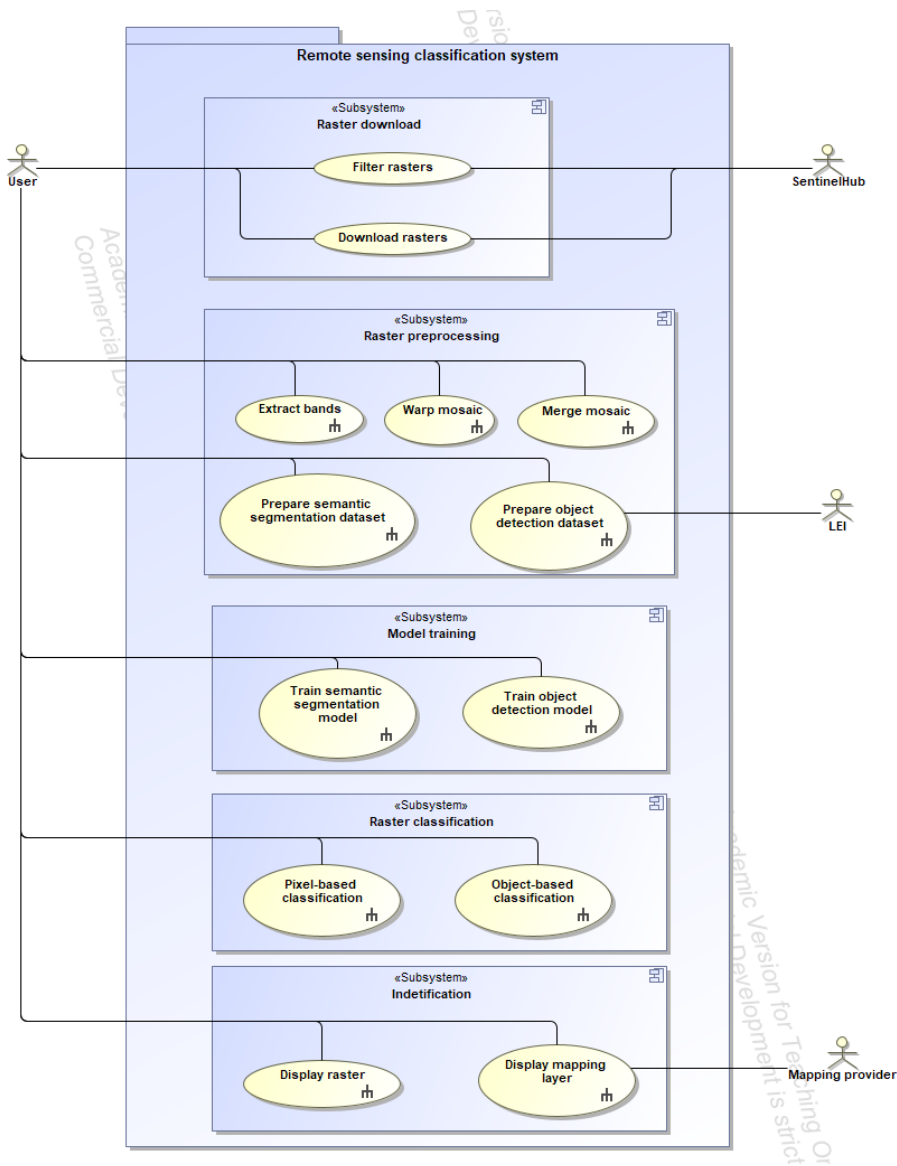
Pradinis planuojamas upės riedulių klasifikavimo posistemės veikimas:

- LEI pateikia Orto vaizdus ir klasifikuotus upės riedulius;
- Sistema sudaro objektų aptikimo modeliui mokytį skirtą duomenų rinkį ir juo apmoko objektų aptikimo modelį;
- Apmokytas modelis panaudojamas klasifikuoti visas pateiktas orto nuotraukas;
- Klasifikavimo rezultatai patalpinami duomenų bazėje;
- Atvaizdavimo sistema naudojasi duomenų bazėje patalpintais vaizdais ir klasifikuotais rieduliais ir juos pateikia per WEB sąsają.

2.2. Funkciniai reikalavimai

2.2.1. Panaudos atvejai

Naudojimo atvejų diagramoje (žr. 2.3 pav.) pateikiamas vienas pagrindinis naudotojas ir du vaizdų teikėjai: *SentinelHub*, skirtas S2 vaizdams atsisiųsti, ir LEI, teikiantis dronų vaizdus ir riedulių objektus. Sistema suskirstyta į penkias atskiras dalis: vaizdų atsisiuntimas, vaizdų apdorojimas, modelio mokymas, vaizdų klasifikavimas ir identifikavimas. Vaizdų atsisiuntimo dalis skirta S2 vaizdų filtravimui ir siuntimui. Vaizdų apdorojimo dalis skirta vaizdų karpymui, jungimui, spektrinių juostų išskyrimams ir duomenų rinkinių skirtų modeliams apmokyti išskyrimui. Modelių mokymo dalis skirta mokytį semantinės segmentacijos ir objektų aptikimo modelius. Vaizdų klasifikavimo dalis skirta klasifikuoti vaizdus su jau mokytais ir klasifikuoti parengtais modeliais. Galiausiai, identifikacijos dalis skirta atvaizduoti galutinius rezultatus, klasifikuotą miškingą teritoriją, bei identifikuotus riedulius upėse. Suskirsčius sistemą į skirtingas dalis, tampa lengviau nustatyti konkrečias kiekvieno komponento funkcijas ir jų tarpusavio sąveiką.



2.3 pav. Panaudos atveju diagrama

2.3. Nefunkciniai reikalavimai

Lentelės naudojamos programinės įrangos sistemos nefunkciniams reikalavimams pateikti. Lentelėje pateikiama pagrindinė informacija, pavyzdžiui, reikalavimo pavadinimas, jo aprašymas, reikalingumo pagrindimas, kas reikalauja, kad jis būtų, ir tinkamumo kriterijai, kuriuos turi atitikti.

Užsakovo pasitenkinimas lentelėje nusako, kaip stipriai nefunkcinio reikalavimo įgyvendinimas įtakoja užsakovo pasitenkinimą:

2.1 lentelė Įgyvendinimo pasitenkinimo įverčiai

Įvertis	Aprašas
1	Mažai įtakoja
2	Šiek tiek įtakoja
3	Vidutiniškai įtakoja
4	Stipriai įtakoja
5	Labai stipriai įtakoja

Užsakovo nepasitenkinimas lentelėje nusako, kaip stipriai nefunkcinio reikalavimo neįgyvendinimas įtakoja užsakovo pasitenkinimą:

2.2 lentelė Neįgyvendinimo nepasitenkinimo įverčiai

Įvertis	Aprašas
1	Mažai įtakoja
2	Šiek tiek įtakoja
3	Vidutiniškai įtakoja
4	Stipriai įtakoja
5	Labai stipriai įtakoja

2.3.1. Reikalavimai sistemos išvaizdai

2.3 lentelė. Aiškaus atvaizdavimo nefunkcinis reikalavimas

Reikalavimas	NF-01		
Aprašymas	Aiškus atvaizdavimas atskiriant miškinga teritorija ryškia spalva		
Pagrindimas	Galimybė greitai susidaryti aiškų miškingos teritorijos padengimo vaizdą		
Šaltinis	Projekto užsakovas A. Šidlauskas		
Atitikimo kriterijus	Atvaizdavimo posistemėje matomi ryškia spalva išskirti atpažinta miškinga teritorija		
Užsakovo pasitenkinimas	5	Užsakovo nepasitenkinimas	4
Prioritetas	Aukštas		

2.3.2. Reikalavimai panaudojamumui

2.4 lentelė. Patogaus atvaizdavimo nefunkcinis reikalavimas

Reikalavimas	NF-02		
Aprašymas	Patogus atvaizdavimo būdas		
Pagrindimas	Galimybė kelių paspaudimų pagalba atlikti visą atvaizdavimo funkcionalumą		
Šaltinis	Projekto užsakovas A. Šidlauskas		
Atitikimo kriterijus	Atvaizdavimo posistemėje galima keisti sluoksnius ne daugiau, kaip 3 paspaudimais		
Užsakovo pasitenkinimas	3	Užsakovo nepasitenkinimas	2
Prioritetas	Vidutinis		

2.5 lentelė. Kalbos nefunkcinis reikalavimas

Reikalavimas	NF-03		
Aprašymas	Naudotojui sistema pateikiama tik anglų kalba		
Pagrindimas	Įgyvendinti grafinę sąsają daugiau kalbų negalima, dėl biudžeto apribojimų		
Šaltinis	Projekto užsakovas A. Šidlauskas		
Atitikimo kriterijus	Visa vartotojo sąsaja yra paruošta anglų kalba		
Užsakovo pasitenkinimas	5	Užsakovo nepasitenkinimas	5

Prioritetas	Aukštas
--------------------	---------

2.6 lentelė. Kvotos likučio stebėjimo nefunkcinis reikalavimas

Reikalavimas	NF-04		
Aprašymas	Siunčiantis vaidus naudotojui pateikiama informacija, jeigu kvotos likutis išnaudotas		
Pagrindimas	Vaizdams nustojus siųstis ir sistemai padarius pertrauką, turi būti aiškiai nurodoma kodėl, jog neatrodytu, kaip klaidingas veikimas		
Šaltinis	Projekto užsakovas A. Šidlauskas		
Atitikimo kriterijus	Vartotojo sąsaja atvaizduoja kvotos išnaudojimą		
Užsakovo pasitenkinimas	2	Užsakovo nepasitenkinimas	1
Prioritetas	Žemas		

2.3.3. Reikalavimai sistemos priežiūrai

2.7 lentelė. Pritaikymo veikti skirtingose operacinėse sistemose nefunkcinis reikalavimas

Reikalavimas	NF-05		
Aprašymas	Sistema yra pritaikyta veikti skirtingose operacinėse sistemose		
Pagrindimas	Sistemos atskirti posistemiai gali būti paleidinėjami tarp skirtingų operacinių sistemų		
Šaltinis	Projekto užsakovas A. Šidlauskas		
Atitikimo kriterijus	Sistemą galima paleisti Windows10 (ir aukštesnėse) ir Linux (Ubuntu 18.04 ir aukštesnėse) operacinėse sistemose		
Užsakovo pasitenkinimas	3	Užsakovo nepasitenkinimas	3
Prioritetas	Vidutinis		

2.3.4. Atitikties reikalavimai

2.8 lentelė. Koordinačių sistemos konvertavimo nefunkcinis reikalavimas

Reikalavimas	NF-06		
Aprašymas	Koordinačių sistemos konvertavimas turi atitikti EPSG (Geodetic Parameter Dataset)		
Pagrindimas	Tai yra populiariausias standartas		
Šaltinis	Projekto užsakovas A. Šidlauskas		
Atitikimo kriterijus	Sistema konvertuoja koordinacijų sistemą pagal EPSG standartą		
Užsakovo pasitenkinimas	3	Užsakovo nepasitenkinimas	3
Prioritetas	Vidutinis		

3. Tyrimas

Tyrimus sudaro trys atskiros dalys, kurių kiekviena skirta tam tikram nuotolinio stebėjimo semantinio segmentavimo ir objektų aptikimo tobulinimo aspektui. Pirmojoje tyrimo dalyje lyginami skirtingi duomenų rinkinių kūrimo šaltiniai – OSM ir HRL, siekiant automatiškai sukurti duomenų rinkinius ir juos apmokyti semantiniam segmentavimui. Antroje dalyje daugiausia dėmesio skiriama skirtingiems palydovo S2 spektrinių juostų deriniams palyginti, siekiant nustatyti, kokią įtaką skirtingi deriniai gali turėti semantinio segmentavimo modeliui. Galiausiai trečiojoje tyrimo dalyje dronų vaizdai bus naudojami objektų aptikimo modeliui, pagal kurį galima klasifikuoti riedulius upėje, apmokyti. Atliekant šiuos tris bandymus, tyrimu siekiama pateikti naudingų įžvalgų ir pastebėjimų kurie būtų aktualūs nuotolinių stebėjimų klasifikavimo sričiai.

3.1. Miškingumo tyrimas

3.1.1. Tyrimo teritorija

Tyrimo teritorija pasirinkta Lietuva. Lietuvos teritoriją daugiausia sudaro lygumos su ežerais, pelkėmis ir miškais. Vyraujančios rūšys – pušys, eglės ir beržai. Lietuvos plotas – 65 300 km². Pagrindinė priežastis, dėl kurios tyrimo teritorija apsiribojo viena šalimi, yra ta, kad modelių mokymo ir vertinimo metu būtų išvengta naujų miškų tipų įvedimo.

3.1.2. Skirtingų spektrinių juostų kompozitai


Miškingos teritorijos tyrimas apsiriboja trijų skirtingų spektrinių juostų kompozitais: tikros spalvos vaizdo (angl. *True Color Image*, TCI), netikros spalvos vaizdo (angl. *False Color Image*, FCI) ir trumpųjų infraraudonųjų bangų vaizdo (angl. *Short-Wave infrared Image*, SWI). TCI kompozitas sujungia raudoną, žalią ir mėlyną spektrines juostas, taip sukurdamas natūraliai atrodantį vaizdą, atitinkanti žmogaus regėjimą. Ši kompozicija idealiai tinka vizualiniam interpretavimui ir aiškiai parodo žemės dangos ypatybes, pavyzdžiui, augmeniją, vandens telkinius ir miestų teritorijas. FCI kompozicijoje naudojamos raudona, žalia ir artimųjų infradonųjų spindulių spektrinės juostos. Pakeitus mėlyną juostą artimųjų infraraudonųjų spindulių spektrine juosta, ši kompozicija padidina kontrastą tarp skirtingų žemės dangos tipų, todėl juos lengviau atskirti. Atskyrimas tampa naudingas vertinant augmenijos būklę, nes sveika augmenija atrodo šviesi, o pažeista augmenija – tamsi. Galiausiai, SWI kompozitas sukuriama derinant raudoną, artimųjų infraraudonųjų spindulių ir trumpųjų bangų infraraudonųjų spindulių spektrines juostas. Šis kompozitas atskleidžia unikalią informaciją apie scenos sudėtį, įskaitant geologines struktūras, dirvožemio drėgmę ir vandens kiekį. Kuriant SWI kompozitą kyla problema, kad viena iš spektrinių juostų turi mažesnę skiriamąją gebą (vietoj 10 m, turi 20 m). Problemą išspręsti buvo panaudotas bilinijinis (angl. *Bilinear*) interpoliavimas, kuris leidžia apjungiant spektrines juostas ir taip paaukštinti spektrinės juostos skiriamąją gebą.

3.1 lentelė Spektrinių juostų kombinacijų sudarymas (pagal 1.2.1.2 skyrelyje pateikiamas spektrines juostas)

Spektrinės juostos vieta			Kombinacijos pavadinimas
R	G	B	
B4	B3	B2	TCI
B8	B4	B3	FCI
B12	B8	B4	SWI

3.1.3. Lietuvos mozaika

Tyrimo teritorijos mozaika yra vienas vaizdas, sujungtas iš daugelio S2 vaizdų po to, kai jiems yra atkeltas apdorojimas. Apdorojimas apima S2 vaizdų tinkamų spektrinių juostų atrinkimą ir karpymą į mažas dalis ir dalių apjungimą į vieną bendrą vaizdą. Nors vienas S2 vaizdas užima tik dalį tiriamosios teritorijos, jame gali būti debesų. Vaizdų sritys, kuriose yra didelis debesuotumas, yra netinkamos naudoti. Vadinasi, šiuos debesis reikia „pašalinti“ iš tiriamosios teritorijos. Pašalinimo metodas apima vieno S2 vaizdo apkarpyimą į mažas dalis, tada naudojant debesų kaukę (kuri gaunama kartu su S2 vaizdu) ignoruojami vaizdai, kuriuose yra debesų. Jei visi tam tikros srities vaizdai srityje turi debesuotumą, pasirenkame vaizdą su mažiausiu debesuotumu. Šiame tyrime mozaika buvo sukurta iš S2 vaizdų kurie buvo fiksuoti 2018 m. vasaros laikotarpiu. Šių metų pasirinkimas buvo motyvuotas būtinybe jį suderinti su naujausiais HRL duomenimis. Kadangi S2 vaizdai yra stipriai įtakojami debesuotumo ir debesų šešėlių, pirmenybė buvo teikiama mėnesiui su mažiausiu debesuotumu. Birželio mėnuo pateikė daugiausiai vaizdų, kuriuose debesuotumas buvo labai žemas (mažiau nei 3%), todėl šis mėnuo buvo pasirinktas tyrimui atlikti. Norint sukurti vieną tyrimo teritorijos vaizdą buvo panaudoti 21 S2 vaizdai.



3.1 pav. Sudaryta Lietuvos mozaika a) TCI vaizdas b) FCI vaizdas c) SWI vaizdas.

3.1.4. Atsitiktinių taškų generavimas

Viena iš pagrindinių automatiškai generuojamų duomenų rinkinių privalumų – galimybė lengvai keisti duomenų rinkinio dydį. Be to, galima pasirinkti konkrečius dominančius plotus, iš kurių bus generuojami duomenų rinkiniai. Šiose srityse galima nurodyti taškus arba juos parinkti atsitiktine tvarka. Šiuo atveju taškai buvo generuojami atsitiktine tvarka visoje tyrimo teritorijoje. Lietuvos vaizdas turi priskirtas geokoordinates. Naudojantis šiomis koordinatėmis galima nustatyti geografinės platumos ir ilgumos ribas. Šios ribos naudojamos dviem atsitiktiniams skaičiams generuoti: vienas – geografinėi platumai, kitas – geografinėi ilgumai. Du atsitiktiniai sugeneruoti skaičiai sudaro tašką. Tada galima apskaičiuoti, ar sugeneruotas taškas patenka į tiriamosios teritorijos poligoną. Sugeneravus reikiamą skaičių atsitiktinių taškų, esančių tiriamoje teritorijoje, šiuos taškus galima naudoti fiksuoto dydžio vaizdams iš tiriamos teritorijos iškirpti. Naudojant šį metodą galima sukurti atsitiktinių vaizdų poaibį. Vėliau šie poaibiai naudojami kaip naujų duomenų rinkinių pagrindas.

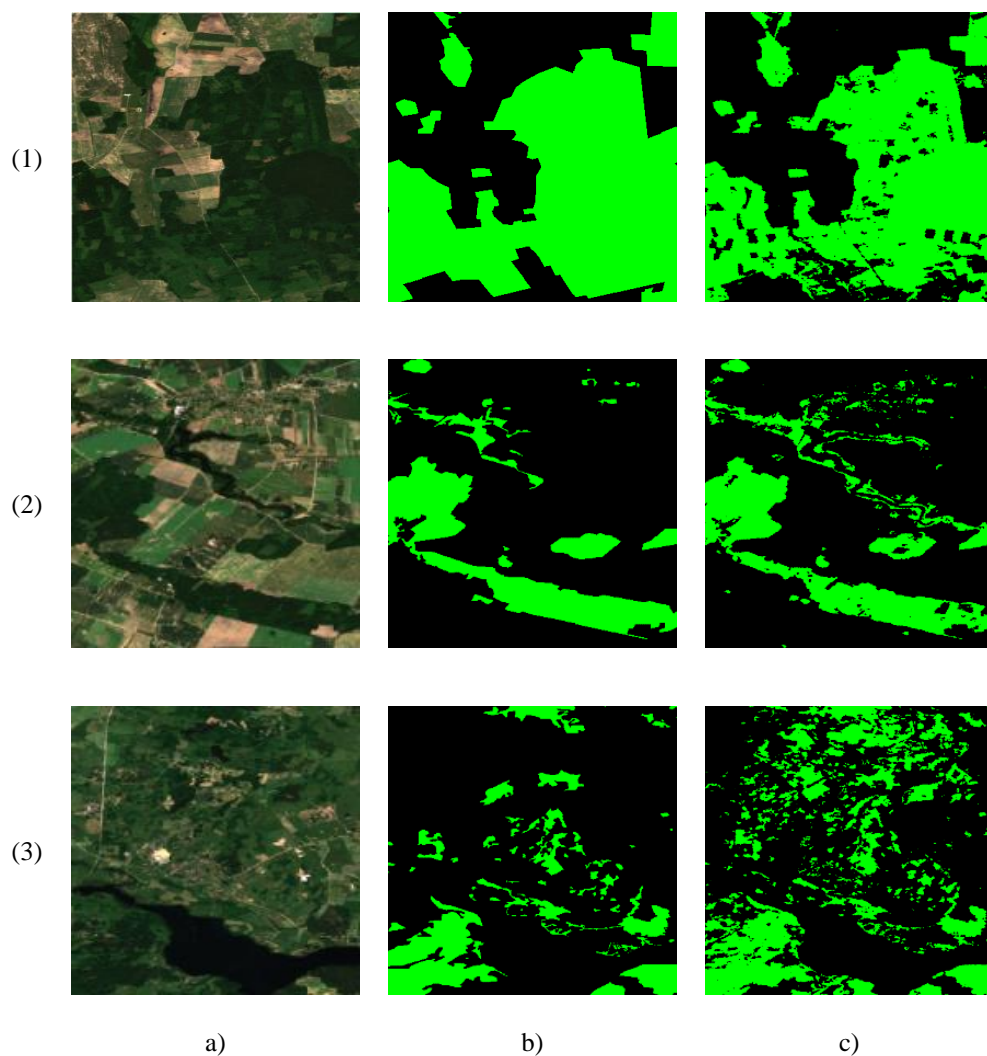


3.2 pav. Atsitiktiniu būdu sugeneruoti taškai Lietuvos teritorijoje. Vaizde pateikiama 1600 taškų.

3.1.5. Duomenų rinkinių sudarymas

3.1.5.1. Duomenų rinkiniai iš skirtingų duomenų šaltinių

Buvo sukurti trys atsitiktiniai taškų pogrupiai, kuriuos sudarė atitinkamai 800, 1600 ir 3200 taškų. Kiekvienam taškui sukurtas 200x200 taškų dydžio vaizdas. S2 TCI vaizdai turi 10 m erdvinę skiriamąją gebą. Iš to vienas vaizdas sudaro kvadratą, kurio viena kraštinė yra 2000 m, bendras vaizdo plotas yra 4 km². Siekiant sukurti duomenų rinkinius, kiekvienas vaizdų poaibis dubliuojamas, tai daroma tam, kad būtų galima sukurti duomenų rinkinius iš tų pačių taškų, vienintelis šių duomenų rinkinių skirtumas – jų kaukės. Kiekvienas duomenų rinkinio vaizdas turi kaukės vaizdą. Kaukės vaizduose pateikiama pagrindiniam vaizdui atitinkantis vaizdas kuriame kiekvienas vaizdo taškas yra priskiriamas klasei. Iš 800 atsitiktinai sugeneruotų taškų buvo sukurti 2 duomenų rinkiniai – 800 vaizdų ir OSM kaukės bei 800 vaizdų ir HRL kaukės. Galiausiai kiekvienas duomenų rinkinys buvo padalytas į 9/10 mokymo vaizdų ir 1/10 validacijos vaizdų. Žemiau (žr **3.3 pav.**) pateikiami keli pavyzdžiai, paaiškinantys ryškiausius sugeneruotų kaukių skirtumus. Pirmajame pavyzdyje matoma, kad OSM duomenų kaukės pateikia apibendrintą miško plotą, kuriame neatsižvelgiama į jokių miško kirtimus, kita vertus HRL kaukė atsižvelgia į kirtimus. Antrajame pavyzdyje matoma, kad OSM kaukės neturi priskyrusios klasių palei upę esančiai miškingai teritorijai. Paskutiniame pavyzdyje pateikiamas ne vienas didesnis miško plotas, o nedideli miškų plotai, ir vėlgi OSM yra blogesnėje padėtyje, nes trūksta daug poligonų mažiems miško plotams nustatyti.




3.3 pav. S2 vaizdas ir sukurtos miško (žalia) ir ne miško (juoda) kaukės; a) tikros spalvos vaizdas (TCI), 10m skiriamoji geba b) iš OSM duomenų sukurtos kaukės c) iš HRL duomenų sukurtos kaukės

Galutiniam vertinimui (testavimui) sukurti du nauji unikalūs duomenų rinkiniai, vienas iš jų pagrįstas HRL duomenimis, kitas – OSM duomenimis. Šie duomenų rinkiniai buvo sukurti tuo pačiu principu kaip ir mokymo duomenų rinkiniai. Vieną duomenų rinkinį sudaro 200 vaizdų. Po mokymo visi modeliai bus papildomai vertinami naudojant šiuos duomenų rinkinius, o tai reiškia, kad vertinant modelius, ir HRL, ir OSM duomenys bus laikomi tikromis reikšmėmis. Vertinimo duomenų rinkiniai buvo sukurti tam, kad būtų galima įvesti naujus vaizdus, kurie nebuvo apdoroti modeliais, ir patikrinti jų tikslumą. Be to, abu duomenų rinkiniai leidžia vertinti modelius pagal tuos pačius duomenis, nes mokymo metu jie turi savo validacijos poaibį.

3.1.5.2. Duomenų rinkiniai iš skirtingų spektrinių juostų kompozitų

Duomenų rinkiniams iš skirtingų spektrinių juostų kompozitų tirti buvo sugeneruoti papildomi 3200 taškų. Tada šie taškai buvo suskirstyti į tris atskirus duomenų rinkinius, kurių kiekvienas buvo pagrįstas skirtingu S2 kompozitu. Pirmojo duomenų rinkinio pagrindas – TCI kompozitas. Antrajame duomenų rinkinyje naudotas FCI kompozitas, o trečiajame – SWI kompozitas. Kiekvieną duomenų rinkinį vėl sudarė 200x200 taškų dydžio vaizdai. Kaip ir anksčiau, duomenys buvo suskirstyti į mokymo ir validacijos rinkinius santykiu 9/10 mokymo ir 1/10 validacijos rinkinių. Visuose duomenų

rinkiniuose kaukių kūrimui naudoti HRL duomenys. Papildomas tik testavimui skirtas duomenų rinkinys nebuvo sukurtas, nes šiuo atveju visi duomenų rinkiniai susideda iš vienodų fiksuotų taškų ir validacijos rinkinių apimtis yra vienoda. Be to duomenų rinkinio sudarymui naudotas tik vienas kaukių sudarymo šaltinis.



3.4 pav. Duomenų rinkinių pavyzdžiai 1) Kompozito vaizdas 2) HRL vaizdo kaukė. Raidės indikuoja skirtingus duomenų rinkinius a) TCI kompozito b) FCI kompozito c) SWI kompozito

3.1.6. Tikslumo skaičiavimo metrika

Kadangi duomenų rinkiniai turi dvi klases – miškas ir ne miškas. Sankirtos koeficientas apskaičiuojamas pagal formulę:

$$mIoU = \frac{IoU_{miškas} + IoU_{ne\ miškas}}{2} \quad (4)$$

čia $mIoU$ – vidutinis sankirtos koeficientas (angl. *mean Intersection over Union*);

IoU – sankirtos koeficientas (pagal atitinkamą klasę), apskaičiuojamas pagal 1.2.3.4 skyrelyje pateikiamas formules.

3.1.7. Klasifikavimo modelių parinkimas

Tyrime semantinis segmentavimas yra suskirstytas į dvi atskiras dalis, kurių kiekviena turi savo duomenų rinkinius ir modelius. Pirmoji dalis apima šešis skirtingus duomenų rinkinius, kurie bus naudojami šešiams atskiriems modeliams apmokyti. Atsižvelgiant į didelį skaičių modelių, kuriuos reikia apmokyti, pasirinktas paprastesnis ir greitesnis FCN modelis su ResNet-50 pagrindu. Antroje tyrimo dalyje yra trys skirtingi duomenų rinkiniai, kuriuos reikia apmokyti trimis atskirais modeliais. Atsižvelgiant į mažesnį skaičių modelių šiame scenarijuje, teikiama pirmenybė kuo didesnio tikslumo pasiekimui, pasirinktas DeepLab modelis ir ResNet-101 pagrindas.

3.2. Upės riedulių tyrimas

3.2.1. Tyrimo teritorija

Šiame tyrime LEI pateikė keturių upių, t. y. Verknės, Širvintos, Jūros ir Vadagių, vaizdus iš dronų. Kai kurie iš šių vaizdų iš drono buvo užfiksuoti kelis kartus, todėl buvo galima išsamiau analizuoti upių ekosistemos pokyčius laikui bėgant. Naudojant dronų technologiją gaunami didelės raiškos vaizdai, kurie yra labai naudingi vertinant upių fizinių savybių, pavyzdžiui, nuosėdų susidarymo ir erozijos, pokyčius, taip pat augalijos ir gyvūnijos, priklausomos nuo šių vandens kelių, pokyčius.

3.2.2. Duomenų surinkimas


Pasirinktos tyrimų teritorijos atveju orto vaizdai surinkti naudojant *DJI Phantom 4 Pro RTK UAV*. Pirmiausia pasirinktos upės atkarpos vietoje buvo įrengti penki antžeminiai kontroliniai taškai (keturi kampuose ir vienas centre), kurių tikslios koordinatės buvo išmatuotos GNSS GPS imtuvu *GeoMax Zenith 40*. Vaizdų fiksavimas atliktas automatiškai, naudojant skrydžio misiją gimtojoje DJI programinėje įrangoje. Skrydžio misija buvo vykdoma 35 m aukštyje virš žemės paviršiaus, kad būtų gauta pradinė apie 1 – 2 cm² vieno taško raiška.



3.5 pav. Drono fiksuotas vaizdas (Vadagai)

3.2.3. Upės riedulių sužymėjimas


Rankinis riedulių ženklavimas yra daug laiko reikalaujantis procesas. Todėl riedulius vaizduojantis sluoksnis turėtų būti kuriamas automatiškai be rankinio žymėjimo. Atskaitos taškui sukurti, LEI ekspertai rankinių būdų klasifikavo visus orto vaizdus. Rieduliai klasifikuojami į du pagrindinius tipus – rieduliai virš vandens (angl. *Boulders Above Water*, BAW) ir rieduliai po vandeniu (angl. *Boulders Under Water*, BUW).



3.6 pav. Klasifikuoti rieduliai upėje (Vadagai), žalia spalva žymi BAW klasę, raudona BUW klasę

3.2.4. Duomenų rinkinių generavimas

Kadangi bendrai egzistuoja 6 orto vaizdai su klasifikuotais rieduliais upėse, nustatyta, jog duomenų aibė yra per maža, kad būtų galima atsitiktinai sudaryti duomenų rinkinius. Siekiant išvengti tos pačios geografinės teritorijos naudojimo modeliui mokyti ir jo rezultatams vertinti, skirtingi modeliai buvo sukurti taikant k kartų kryžminę patikrą (angl. *k-fold cross validation*). Pirmiausia, naudojant morfologinį skeleto formavimo algoritmą, buvo sudaryta centrinė upės regiono linija. Tada ji buvo padalinta į 5 vienodas dalis, o upės regionas padalytas į segmentus linija, statmena centrinei linijai.



3.7 pav. Upės išskaidymas į ruožus

Padalinus orto vaizdus pagal regionus galima sudaryti duomenų poaibus mokymo ir validacijos duomenims generuoti. Generuojant duomenų rinkinius pasirinkta keturis upių regionus skirti mokymo poaibiui ir vieną poaibį validacijos duomenims. Generuojant naują kryžminę iteraciją pakeičiamas tikrinimo poaibis, kaip pateikiama žemiau (žr. 3.8 pav.).



3.8 pav. K kartų kryžminė patikra. Raudona spalva pažymėtos mokymo aibės, geltona spalva validacijos aibės. Vaizde pateikiamas 3 kartų kryžminės patikros pavyzdys.

Vaizdams generuoti pasirinkta 2000x2000 erdvinė raiška. Raiška pasirinkta, dėl potencialiai įvairaus riedulių dydžio. Šis pasirinkimo dydis užtikrina, jog didžiausi galimi rieduliai taip pat tilps viename vaizde. Vieną duomenų rinkinį sudaro apie 500 vaizdų, kuriame mokymo ir validavimo duomenų rinkinių santykis yra 4:1.

Žemiau pateiktoje lentelėje yra parodomas bendras riedulių pasiskirstymas. Patikros numeris nurodo poaibi, toliau pateikiami bendri kiekiai riedulių virš vandens ir po vandeniu.

3.2 lentelė Riedulių bendras pasiskirstymas per visus vaizdus pagal poaibį


Kryžminės patikros nr.	Riedulių po vandeniu kiekis	Riedulių virš vandeniu kiekis
1	175	102
2	531	457
3	169	99
4	204	239
5	389	200

4. Eksperimentas

4.1. Miškingumo eksperimentas

4.1.1. Duomenų rinkinių sudarytų iš skirtingų šaltinių mokymo rezultatai

Kiekvienas modelis buvo apmokytas 1000 epochų su savo duomenų rinkiniu. Kiekvieno duomenų rinkinio kaukės buvo sukurtos iš savo duomenų šaltinio. Matoma (žr. **4.1 pav.**), kad taškų tikslumas iš esmės panašus visuose duomenų rinkiniuose. Tačiau mIoU rezultatai labiau skiriasi su OSM duomenų rinkiniais. Mažesnę mIoU galima priskirti OSM netikslumams. Šio duomenų rinkinio validacijos duomenys gali turėti miško plotų, kurie nepamėti kaip miškas, todėl tai turi įtakos validacijos rezultatams. Padidinus mokymo duomenų rinkinio dydį, taip pat buvo gauti geresni validacijos rezultatai mokymo metu.



4.1 pav. Validacijos rezultatai mokymosi metu su skirtingais duomenų rinkiniais a) matuojama taškų tikslumu (PA) b) matuojama pagal vidutinį sankirtos koeficientą (mIoU)

4.1.1.1. Testavimo rezultatai

Apmokyti modeliai buvo vertinami naudojant du skirtingus duomenų rinkinius, kurių vienas pagrįstas HRL duomenimis, o kitas – OSM duomenimis. Žemiau (žr. **4.1 lentelė**) pateikiami HRL duomenų

rinkinio testavimo rezultatai, ir OSM duomenų rinkinio testavimo rezultatai (žr. **4.2 lentelė**). Remiantis rezultatais motama, kad abu modeliai gerai prisitaikė prie savo mokymo duomenų rinkinių. Vertinant HRL apmokytus modelius su naujai sukurtu HRL vertinimo duomenų rinkiniu, jis veikia geriau nei duomenų rinkinys, apmokytas su OSM duomenimis. Tačiau vertinant atvirksčiai, OSM apmokyti duomenų rinkiniai veikia geriau. Be to, galima pastebėti, kad modelių su didesnio dydžio mokymo duomenų rinkiniais tikslumas buvo šiek tiek geresnis, ypač testuojant pagal to paties šaltinio duomenų rinkinį. Abu modeliai pasiekia panašią tikslumo ribą – ~0,92 PA ir ~0,84 mIoU, kai yra vertinami pagal savo atitinkama testavimo duomenų rinkinį. Remiantis šiais vertinimo rezultatais, negalima teigti, kad HRL arba OSM pasirodė esantys geresni pagrindinės tiesos šaltiniai. Tiesiogiai palyginti šių rezultatų su cituojamais dokumentais negalima, nes daugelyje šaltiniu tikrosios reikšmės laikomi skirtingų šaltinių duomenys.

4.1 lentelė Testavimo rezultatai vertinant pagal HRL testavimo duomenų rinkinį

Duomenų šaltinis	Duomenų rakinio dydis	Taškų tikslumas (PA)	Vidutinis sankirtos koeficientas (mIoU)
HRL	800	0,891	0,798
HRL	1600	0,907	0,828
HRL	3200	0,917	0,843
OSM	800	0,844	0,717
OSM	1600	0,859	0,742
OSM	3200	0,854	0,734


4.2 lentelė Testavimo rezultatai vertinant pagal OSM testavimo duomenų rinkinį

Duomenų šaltinis	Duomenų rakinio dydis	Taškų tikslumas (PA)	Vidutinis sankirtos koeficientas (mIoU)
HRL	800	0,872	0,758
HRL	1600	0,861	0,741
HRL	3200	0,859	0,738
OSM	800	0,902	0,802
OSM	1600	0,910	0,819
OSM	3200	0,921	0,838

4.1.1.2. Pastebimi skirtumai

Nors vertinimo rezultatai yra labai panašūs, tam tikrus skirtumus galima nustatyti vizualiai patikrinus, kaip modeliai prognozuoja labiau išskirtinius atvejus kurie buvo aprašyti 3.1.5 skyrelyje. Pateiktame palyginime (žr. **4.2 pav.**) matomi skirtingi modelių klasifikavimai. Pirmajame pavyzdyje matoma, kad OSM apmokytas modelis ignoruoja miško kirtavietes, o HRL apmokytas modelis atpažįsta kirtavietes, nors ir nevisiškai tiksliai. Abu modeliai vis tiek patyrė didelių netikslumų, kai reikėjo atpažinti miško kirtavietes didelėse miškingose teritorijose. Modeliai paprasčiausiai žymėdavo visą plotą žymėti kaip mišką ir ignoruodavo kirtavietes. Antrajame pavyzdyje pateikiami įrodymai, kad HRL modeliai geriau atpažįsta miško plotus palei upes. Kadangi OSM retai pateikia miško poligonų plotus palei upes ir ežerus, HRL apmokyti modeliai juos atpažįsta geriau. Kai kalbama apie mažas upes, OSM modeliai

yra linkę visiškai ignoruoti miško plotus aplink upes, o HRL apmokyti modeliai turi pasikartojančią problemą – dažnai pačią upę atpažįsta kaip mišką. Paskutiniame pavyzdyje parodyta, kad OSM susiduria su problema atpažindamas mažus miško plotus. Tai turbūt labiausiai pastebimas skirtumas. Kita vertus, HRL modelis labai gerai atpažįsta šiuos lopinėlius, tačiau kartais jis gali atpažinti didesnius plotus, kurie nebepatenka į mažų miško lopinėlių ribas.





4.2 pav. Apmokyto modelio klasifikavimo pavyzdžiai a) S2 vaizdai, 10m erdvinė skiriamoji geba b) klasifikavimas, modelis apmokytas su OSM duomenimis c) klasifikavimas, modelis apmokytas su HRL duomenimis.



4.1.2. Duomenų rinkinių sudarytų iš skirtingų spektrinių juostų kompozitų mokymo rezultatai

Kiekvienas duomenų rinkinys buvo apmokytas 100 epochų su savo atitinkamu duomenų rinkiniu. Žemiau pateikiami (žr. **4.3 pav.**) mokymo patikros rezultatai. Mokymo rezultatai rodo, kad taškų tikslumas tarp įvairių vaizdų kompozitų reikšmingai nesiskyrė ir svyravo nuo 0,92 iki 0,94. Tačiau vertinant vidutinį sankirtos koeficientą, pastebėtas ryškesnis skirtumas – vertės svyravo nuo 0,82 iki 0,88. Tai rodo, kad nors modeliai panašiai veikė teisingai klasifikuodami pavienius vaizdo taškus, jų gebėjimas tiksliai apibrėžti objektų ribas ir perteikti bendrą objektų formą bei struktūrą skyrėsi labiau. Vidutinių sankirtos koeficiento verčių skirtumai rodo, kad modeliai, apmokyti su tam tikrais vaizdų kompozitais, geriau segmentavo ir lokalizavo objektus.

1)



2)



a)

b)

4.3 pav. Validacijos rezultatai mokymosi metu. Melyna spalva žymimi SWI kompozito rezultatai, orandžinė FCI kompozito ir žalia TCI kompozito. Viršuje pateikiamas vaizdo taškų tikslumas (PA), apačioje vidutinis sankirtos koeficientas (mIoU) a) pateikiamos metrikos skalėje nuo 0 iki 1 b) pateikiamos metrikos skalėje nuo 0,7 iki 1,0

4.1.2.1. Testavimo rezultatai

Testavimo metu apmokytų modelių veikimui įvertinti buvo naudojamas tas pats tikrinimo duomenų rinkinys. Kiekvienam duomenų rinkiniui parinkta epocha kurioje modelis buvo pasiekęs geriausius tikrinimo rezultatus. Žemiau (žr **4.3 lentelė**) pateikiami testavimo rezultatai. Matoma, kad taškų tikslumas išlieka panašus tarp skirtingų kompozitų. Kita vertus, vidutinis sankirtos koeficientas svyruoja kiek daugiau nuo 0,847 iki 0,882. Atlikus testavimą matoma, kad geriausius rezultatus pasiekia iš FCI kompozito sudarytų duomenų rinkinių apmokomi modeliai. Praščiausi rezultatai gaunami iš modelių kurie buvo apmokomi naudojant SWI kompozito duomenų rinkinius. Šio kompozito netikslumus galėjo įtakoti ir pasirinktas interpoliavimo metodas, kuris buvo skirtas suvienodinti vaizdo skiriamąją gebą. Toliau skirtumai tarp spektrinių juostų gali būti priskiriami jų paviršių atspindžių savybėms.

4.3 lentelė Testavimo rezultatai pagal kompozitus

Kompozitas	Taškų tikslumas (PA)	Vidutinis sankirtos koeficientas (mIoU)
TCI	0,930	0,863
FCI	0,941	0,882
SWI	0,922	0,847

4.1.3. Tyrimo išvados

Pirmos grupės duomenų rinkinių vertinimas parodė, kad abu duomenų šaltiniai davė panašius skaitinio tikslumo rezultatus. Iš abiejų duomenų šaltinių gauti tikslūs duomenys, kurie leido modeliams pasiekti ~0,92 PA ir ~0,84 mIoU, vertinant su atitinkamais duomenų šaltinio duomenų rinkiniais. Atliekant vertinimą taip pat pastebėta, kad didinant mokymo duomenų rinkinio dydį didėjo modelių tikslumas. Papildomai vizualiai patikrinus kraštutinius atvejus, pastebėta, kad su OSM duomenų rinkiniais apmokyti modeliai buvo linkę neklasifikuoti miško plotų šalia upių ir neklasifikuoti nedidelių miškingų plotų laukuose. Modeliai, kurie buvo apmokyti naudojant HRL duomenų rinkinius, geriau klasifikavo miškų kirtavietes, miškų plotus palei upes ir mažus vietovėje miškingus plotus. Tačiau HRL apmokyti modeliai galėjo pateikti klaidingą teigiamą (FP) klasifikaciją, identifikuodami upės dalis kaip mišką.

Antros grupės duomenų rinkinių vertinimas parodė, kad skirtingi vaizdų kompozitai gali įtakoti modelių mokymo galimybes. Įvertinus tris skirtingus kompozitus – TCI, FCI ir SWI, buvo nustatyta, jog geriausius klasifikavimo rezultatus pasiekia modeliai kurie buvo apmokyti iš FCI kompozito sudarytų duomenų rinkinių. Modelis apmokytas naudojant šiuos duomenis pasiekė geriausius rezultatus tarp naudojamų metrikų: 0,941 PA ir 0,882 mIoU. Modelis kuris buvo apmokytas naudojant TCI kompozito duomenų rinkinius pasiekė 0,930 PA ir 0,863 mIoU. Prasčiausius rezultatus rodė SWI kompozito duomenų rinkinys. Šiuo rinkinių apmokytas modelis pasiekė 0,922 PA ir 0,847 mIoU.

4.2. Upės riedulių eksperimentas

4.2.1. Pagrindinio modelio atrinkimas

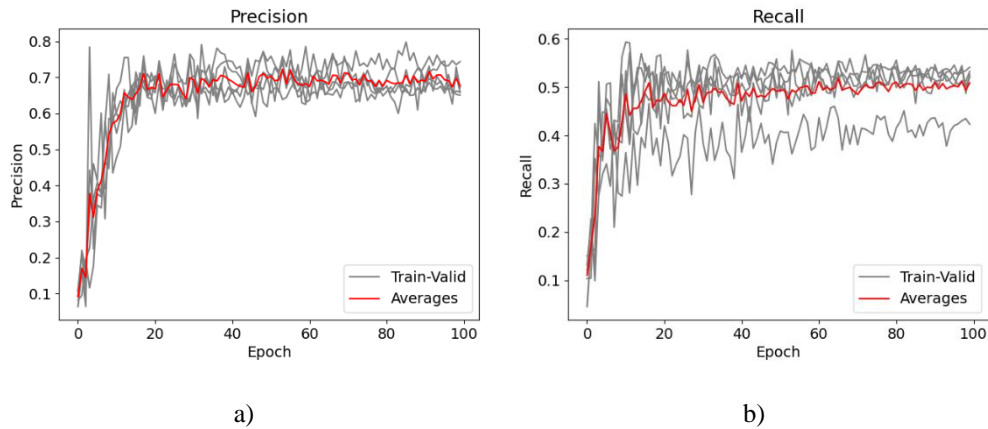
Siekiant palyginti skirtingų YOLOv5 modelio variantų, t. y. YOLOv5s6, YOLOv5m6, YOLOv5l6 ir YOLOv5x6, našumą, buvo atliktas vieno duomenų rinkinio bendras apmokymas. Visiems modeliams apmokyti naudotas vienas atsitiktinai parinktas duomenų rinkinys. Kiekvienas variantas buvo apmokytas naudojant tą pačią mokymo konfigūraciją ir hiperparametrus, kad būtų užtikrintas sąžiningas palyginimas. Išanalizavus rezultatus nustatyta, kad YOLOv5x6 rezultatai buvo šiek tiek geresni nei kitų variantų, nors skirtumai sąlyginai nedideli. Vertinimo rezultatai buvo apibendrinti lentelėje, o remiantis metrikomis ir našumo palyginimu, YOLOv5x6 buvo nustatytas kaip geriausiai veikiantis modelis pagal pateiktą duomenų rinkinį ir vertinimo kriterijus.

4.4 lentelė Skirtingų modelių tikslumo palyginimas (naudojant *train1245-valid3* duomenų rinkinį). Vertinamos abi klasės.

Modelis	Tikslumas (P)	Atpažinimas (R)
YOLOv5s6	0,673	0,533
YOLOv5m6	0,667	0,540
YOLOv5l6	0,649	0,518
YOLOv5x6	0,682	0,536

4.2.2. Kryžminės validacijos modelių mokymas

Riedulių aptikimo užduoties tyrimo objektas buvo dvi skirtingos klasės, pažymėtos kaip rieduliai po vandeniu (BUW) ir rieduliai virš vandens (BAW). Tikslumo ir atpažinimo kreivės mokymo metu tikrinimo duomenų rinkiniams pateiktos žemiau (žr. **4.4 pav.**). Visi duomenų rinkiniai mokymo metu rodė tas pačias tendencijas. Visais atvejais tikslumo reikšmės po 20 epochų reikšmingai nesikeitė. Atpažinimo reikšmės nustojo reikšmingai keistis po 30 epochų.




4.4 pav. Kryžminės validacijos mokymosi metrikos a) tikslumo ir b) atpažinimo. Pilka spalva nurodo specifinę kryžminę validaciją, raudona spalva vidutinę reikšmę.

Apmokius visus duomenų rinkinius, modeliai paskutini kartą yra praleidžiami pro tikrinimo duomenų rinkinį ir yra registruojami galutiniai rezultatai, kurie yra pateikiami žemiau (žr. **4.5 lentelė**). Vidutinis tikslumas BAW klasei siekia $\sim 0,776$, o BUW klasei siekia $\sim 0,633$. Vidutinis atpažinimas BAW klasei siekia $\sim 0,690$, o BUW klasei siekia $\sim 0,391$. Rezultatai parodė, kad visuose duomenų rinkiniuose rodikliai buvo geresni BAW klasei. Akivaizdu, kad BUW klasę aptikti buvo sudėtingiau dėl vandens sluoksnio virš riedulio, augmenijos, vandens paviršiaus nelygumų ir kitų savybių.

4.5 lentelė Objektų kiekis, tikslumas ir atpažinimas pagal duomenų rinkinį.

Rinkinys	Klasė	Objektų kiekis	Tikslumas (P)	Atpažinimas (R)
Train2345-valid1	BAW	809	0,851	0,710
	BUW	1025	0,666	0,443
Train1345-valid2	BAW	2453	0,766	0,797
	BUW	3091	0,578	0,339
Train1245-valid3	BAW	664	0,798	0,664
	BUW	823	0,567	0,408
Train1235-valid4	BAW	1670	0,669	0,764
	BUW	924	0,620	0,360
Train1234-valid5	BAW	1673	0,798	0,515
	BUW	2485	0,734	0,404

Originalaus vaizdo ir riedulinės išvados rezultato pavyzdys pateikiamas žemiau (žr. **4.5 pav.**). Raudoni ir žali riboženkliai rodo laukiamą rezultatą, t. y. rankiniu būdu paženklintus BAW ir BUW klasių riboženklus. Kryžminiai žymėjimai nurodo automatinio klasifikavimo rezultatus, paveikslėlyje matoma, kad maži rieduliai yra prastai identifikuojami lyginant su didesniais rieduliais.



a)

b)

4.5 pav. a) Originalus vaizdas b) Raudona ir žalia spalva nusako rankinių būdų sužymėtus riedulius BAW(raudona) ir BUW (žalia). Kryžminės linijos rodo atitinkamai BAW ir BUW automatinio klasifikavimo rezultatus.

4.2.3. Tyrimo išvados

Siekiant išspręsti riboto duomenų rinkinio problemą, riedulių aptikimo modeliui apmokyti buvo pasirinktas k kartų kryžminio validacijos metodas. Modeliu siekta klasifikuoti riedulius į dvi kategorijas: riedulys virš vandens ir riedulys po vandeniu. Iš įvertintų modelių YOLOv5x6 pademonstravo didžiausią tikslumą, todėl modelis buvo pasirinktas mokyti visus duomenų rinkinius.

Riedulių virš vandens klasė pasižymėjo aukštais vidutiniais tikslumo rezultatais – $\sim 0,776$ P, o tai rodo, kad modelis turėjo gerą gebėjimą tiksliai klasifikuoti riedulius virš vandens. Be to, riedulių virš vandens klasė parodė gerus vidutinius atpažinimo rodiklius – $\sim 0,690$ R, o tai rodo, kad modelis sėkmingai identifikavo daugumą šios kategorijos riedulių. Tačiau riedulių po vandeniu klasė pasižymėjo kitokiomis charakteristikomis. Nors vidutiniai tikslumo rezultatai buvo geri – $\sim 0,633$ P, vidutinis atpažinimo rodiklis buvo daug mažesnis – $\sim 0,391$ R. Tai rodo, kad modeliams sunkiai sekėsi tiksliai atpažinti ir klasifikuoti riedulius po vandeniu. Žemas atpažinimo rodiklis rodo, kad modelis nepastebėjo nemažai riedulių po vandeniu, todėl bendras šios klasės našumas buvo mažesnis.

5. Išvados

Projekto metu buvo sukurta nuotolinio stebėjimo klasifikavimo sistema, orientuota į du pagrindinius komponentus: miškų klasifikavimą ir upių riedulių identifikavimą. Toliau su sistema buvo atlikti 3 pagrindiniai tyrimai – automatinio duomenų rinkinio generavimo tyrimas, skirtingų spektrinių juostų kompozitų tyrimas ir upės riedulių aptikimo galimybių tyrimas.

1. Analizės metu nustatyta, kad miškingumo klasifikavimui tinkamiausi S2 palydovai, kurie pasižymi aukšta raiška ir dideliu kiekiu skirtingų spektrinių juostų, o jų klasifikavimui tinkama semantinė segmentacija dėl savo tikslios klasės priskyrimo kiekvienam vaizdo taškui;
2. Analizės metu nustatyta, kad upių rieduliams klasifikuoti tinka dronų vaizdai, kurie fiksuojami nedidelias teritorijas leidžia išgauti didelę raišką, o riedulių klasifikavimui puikiai tinka objektų aptikimas, dėl galimybių aptikti ir lokalizuoti objektus;
3. Tyrimo metu buvo vertinami du duomenų šaltiniai skirti automatiniam duomenų rinkinių generavimui – OSM ir HRL. Įvertinus šiuos duomenų rinkinius paaiškėjo, kad jų rezultatai yra daug žadantys ir tikslūs – ~0,92 PA ir ~0,84 mIoU. Atidžiau išnagrinėjus ribinius atvejus paaiškėjo, kad su kiekvienu duomenų rinkinio šaltiniu egzistuoja apribojimai. OSM pagrįstuose duomenų rinkiniuose buvo sunku aptikti miško plotus, esančius šalia upių, ir nedidelius miško lopinėlius laukuose, todėl segmentavimas nebuvo toks išsamus, kaip HRL pagrįstuose duomenų rinkiniuose. Kita vertus HRL pagrįsti duomenų rinkiniai sėkmingai nustatė šiuos miško plotus ir lopinėlius, tačiau susidūrė su nauja problema – klaidingas upių dalių priskyrimas miško plotams;
4. Tyrimo metu buvo vertinami skirtingi palydovo S2 spektrinių juostų kompozitai skirti apmokyti miškų klasifikavimo modelį. Atlikus tyrimą su trimis skirtingais spektrinių juostų kompozitais: TCI, FCI ir SWI, buvo nustatyta, kad duomenų rinkiniai sudaryti iš FCI kompozito buvo tinkamiausi modelių apmokymui ir pasiekė 0,941 PA ir 0,882 mIoU. Modeliai kurie buvo apmokyti naudojant kitus kompozitus pasiekė prastesnius rezultatus (nuo 0,921 PA iki 0,930 PA ir nuo 0,847 mIoU iki 0,863 mIoU);
5. Tyrimo metu buvo vertinamos upės riedulių klasifikacijos galimybės. Klasifikuojamos dvi klasės – rieduliai virš vandens ir rieduliai po vandeniui. Atlikus pirminį bandymą, nustatyta, kad modelio variacija YOLOv5x6 pasiekia aukščiausius klasifikavimo rezultatus, todėl buvo tinkamiausia naudoti kryžminės validacijos modelių mokymui. Atlikus 5 kartų kryžminę validaciją buvo nustatyta, kad riedulių virš vandens klasė turi aukštus vidutinio tikslumo rezultatus ~0,776 P ir gerus vidutinius atpažinimo rezultatus ~0,690 R. Tai rodo, jog modelis geba atpažinti ir tiksliai lokalizuoti riedulis virš vandens. Tačiau riedulių po vandeniui situacija buvo kitokia, pasiektas geras tikslumo rezultatas ~0,633 P, bet atpažinimo rezultatai buvo žemi ~0,391 R. Iš to daroma išvada, kad reikia dar toliau tobulinti riedulių po vandenių atpažinimo našumą norint gauti labiau subalansuotą abiejų kategorijų klasifikavimą.

Literatūros sąrašas

- [1] R. C. Olsen, *Remote Sensing from Air and Space*. SPIE, 2010. doi: 10.1117/3.673407.
- [2] A. M. Lechner, G. M. Foody, ir D. S. Boyd, „Applications in Remote Sensing to Forest Ecology and Management“, *One Earth*, t. 2, nr. 5. Cell Press, p. 405–412, 2020 m. gegužės 22 d. doi: 10.1016/j.oneear.2020.05.001.
- [3] E. Carfagna ir F. J. Gallego, „Using Remote Sensing for Agricultural Statistics“, 2005.
- [4] A. M. Lechner, G. M. Foody, ir D. S. Boyd, „Applications in Remote Sensing to Forest Ecology and Management“, *One Earth*, t. 2, nr. 5. Cell Press, p. 405–412, 2020 m. gegužės 22 d. doi: 10.1016/j.oneear.2020.05.001.
- [5] C. Bueno-Suárez ir D. Coq-Huelva, „Sustaining what is unsustainable: A review of urban sprawl and urban socio-environmental policies in North America and Western Europe“, *Sustainability (Switzerland)*, t. 12, nr. 11. MDPI, 2020 m. birželio 1 d. doi: 10.3390/su12114445.
- [6] United States Geological Survey, „Satellite Acquisitions“, 2022, doi: 10.3133/fs20153081.
- [7] European Space Agency, „The Sentinel missions“. https://www.esa.int/Applications/Observing_the_Earth/Copernicus/The_Sentinel_missions (žiūrėta 2023 m. balandžio 25 d.).
- [8] N. Munasinghe, „LOW COST AERIAL MAPPING WITH CONSUMER-GRADE DRONES“, 2016. [Interaktyvus]. Adresas: <https://www.researchgate.net/publication/317303854>
- [9] L. Tang ir G. Shao, „Drone remote sensing for forestry research and practices“, *Journal of Forestry Research*, t. 26, nr. 4. Northeast Forestry University, p. 791–797, 2015 m. gruodžio 1 d. doi: 10.1007/s11676-015-0088-y.
- [10] L. Ma, Y. Liu, X. Zhang, Y. Ye, G. Yin, ir B. A. Johnson, „Deep learning in remote sensing applications: A meta-analysis and review“, *ISPRS Journal of Photogrammetry and Remote Sensing*, t. 152. Elsevier B.V., p. 166–177, 2019 m. birželio 1 d. doi: 10.1016/j.isprsjprs.2019.04.015.
- [11] K. O’Shea ir R. Nash, „An Introduction to Convolutional Neural Networks“, lapkr. 2015, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1511.08458>
- [12] S. Bhattacharyya, RCC Institute of Information Technology. Department of Information Technology, ir Institute of Electrical and Electronics Engineers, *Proceedings, 2018 Fourth IEEE International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN) : 22nd and 23rd November, 2018, Kolkata, India*. 2018.
- [13] Z. Zou, Z. Shi, Y. Guo, ir J. Ye, „Object Detection in 20 Years: A Survey“, geg. 2019, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1905.05055>
- [14] R. Girshick, „Fast R-CNN“, bal. 2015, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1504.08083>
- [15] J. Glenn, C. Ayush, ir S. Alex, „ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation“, 2021 m. <https://zenodo.org/record/7347926> (žiūrėta 2023 m. balandžio 27 d.).
- [16] R. Xu, H. Lin, K. Lu, L. Cao, ir Y. Liu, „A forest fire detection system based on ensemble learning“, *Forests*, t. 12, nr. 2, p. 1–17, vas. 2021, doi: 10.3390/f12020217.
- [17] T. Mahendrakar ir kt., „Performance Study of YOLOv5 and Faster R-CNN for Autonomous Navigation around Non-Cooperative Targets“, *IEEE Aerospace Conference Proceedings*, IEEE Computer Society, 2022. doi: 10.1109/AERO53065.2022.9843537.
- [18] M. Thoma, „A Survey of Semantic Segmentation“, vas. 2016, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1602.06541>
- [19] J. Long, E. Shelhamer, ir T. Darrell, „Fully Convolutional Networks for Semantic Segmentation“.

- [20] H. Zhao, J. Shi, X. Qi, X. Wang, ir J. Jia, „Pyramid Scene Parsing Network“, gruodž. 2016, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1612.01105>
- [21] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, ir H. Adam, „Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation“, vas. 2018, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1802.02611>
- [22] P. Rafael, L. N. Sergio, ir A. B. da S. Eduardo, „A Survey on Performance Metrics for Object-Detection Algorithms“, 2020.
- [23] W. Yang ir R. Atiqur, *Advances in Visual Computing*, t. 10072. Lecture Notes in Computer Science, vol. 10072. Cham: Springer International Publishing, 2016. doi: 10.1007/978-3-319-50835-1.
- [24] M. Thoma, „A Survey of Semantic Segmentation“, vas. 2016, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1602.06541>
- [25] A. Jain, A. A. Awan, H. Subramoni, ir D. K. Panda, „Scaling TensorFlow, PyTorch, and MXNet using MVA PICH2 for high-performance deep learning on Frontera“, *Proceedings of DLS 2019: Deep Learning on Supercomputers - Held in conjunction with SC 2019: The International Conference for High Performance Computing, Networking, Storage and Analysis*, Institute of Electrical and Electronics Engineers Inc., lapkr. 2019, p. 76–83. doi: 10.1109/DLS49591.2019.00015.
- [26] P. Goldsborough, „A Tour of TensorFlow“, spal. 2016, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1610.01178>
- [27] A. Asokan ir J. Anitha, „Change detection techniques for remote sensing applications: a survey“, *Earth Science Informatics*. Springer Verlag, 2019 m. doi: 10.1007/s12145-019-00380-5.
- [28] S. T. Thompson ir W. B. Magrath, „Preventing illegal logging“, *Forest Policy and Economics*, t. 128. Elsevier B.V., 2021 m. liepos 1 d. doi: 10.1016/j.forpol.2021.102479.
- [29] E. Grabska, P. Hostert, D. Pflugmacher, ir K. Ostapowicz, „Forest stand species mapping using the sentinel-2 time series“, *Remote Sens (Basel)*, t. 11, nr. 10, geg. 2019, doi: 10.3390/rs11101197.
- [30] N. Puletti, F. Chianucci, ir C. Castaldi, „Use of Sentinel-2 for forest classification in Mediterranean environments“, *Annals of Silvicultural Research*, t. 42, nr. 1, p. 32–38, 2018, doi: 10.12899/ASR-1463.
- [31] M. K. Nisha ir kt., „An assessment of data sources, data quality and changes in national forest monitoring capacities in the Global Forest Resources Assessment 2005–2020“, *Environmental Research Letters*, t. 16, nr. 5. IOP Publishing Ltd, 2021 m. gegužės 1 d. doi: 10.1088/1748-9326/abd81b.
- [32] A. Dostálová, M. Lang, J. Ivanovs, L. T. Waser, ir W. Wagner, „European wide forest classification based on sentinel-1 data“, *Remote Sens (Basel)*, t. 13, nr. 3, p. 1–27, vas. 2021, doi: 10.3390/rs13030337.
- [33] M. Ozdogan, Y. Yang, G. Allez, ir C. Cervantes, „Remote sensing of irrigated agriculture: Opportunities and challenges“, *Remote Sensing*, t. 2, nr. 9. p. 2274–2304, 2010 m. rugsėjo. doi: 10.3390/rs2092274.
- [34] E. Carfagna ir F. J. Gallego, „Using Remote Sensing for Agricultural Statistics“, 2005.
- [35] Q. Feng, J. Liu, ir J. Gong, „Urban flood mapping based on unmanned aerial vehicle remote sensing and random forest classifier-A case of yuyao, China“, *Water (Switzerland)*, t. 7, nr. 4, p. 1437–1455, 2015, doi: 10.3390/w7041437.

- [36] J. Chormanski, T. Okruszko, S. Ignar, O. Batelaan, K. T. Rebel, ir M. J. Wassen, „Flood mapping with remote sensing and hydrochemistry: A new method to distinguish the origin of flood water during floods“, *Ecol Eng*, t. 37, nr. 9, p. 1334–1349, rugs. 2011, doi: 10.1016/j.ecoleng.2011.03.016.
- [37] J. N. Hansen, E. T. A. Mitchard, ir S. King, „Assessing forest/non-forest separability using sentinel-1 C-band synthetic aperture radar“, *Remote Sens (Basel)*, t. 12, nr. 11, birž. 2020, doi: 10.3390/rs12111899.
- [38] Z. Malenovský *ir kt.*, „Sentinels for science: Potential of Sentinel-1, -2, and -3 missions for scientific observations of ocean, cryosphere, and land“, *Remote Sens Environ*, t. 120, p. 91–101, geg. 2012, doi: 10.1016/j.rse.2011.09.026.
- [39] J. Estima ir M. Painho, „Exploratory analysis of OpenStreetMap for land use classification“, *GEOCROWD 2013 - Proceedings of the 2nd ACM SIGSPATIAL International Workshop on Crowdsourced and Volunteered Geographic Information*, Association for Computing Machinery, 2013, p. 39–46. doi: 10.1145/2534732.2534734.
- [40] A. J. Kaeser, T. L. Litts, ir T. W. Tracy, „Using Low-Cost Side-Scan Sonar For Benthic Mapping Throughout The Lower Flint River, Georgia, Usa“, *River Res Appl*, t. 29, nr. 5, p. 634–644, birž. 2013, doi: 10.1002/rra.2556.
- [41] J. M. Buffington ir D. R. Montgomery, „Geomorphic Classification of Rivers“, *Treatise on Geomorphology*, Elsevier Inc., 2013, p. 730–767. doi: 10.1016/B978-0-12-374739-6.00263-3.
- [42] F. Abushakra *ir kt.*, „A Miniaturized Ultra-Wideband Radar for UAV Remote Sensing Applications“, *IEEE Microwave and Wireless Components Letters*, t. 32, nr. 3, p. 198–201, kovo 2022, doi: 10.1109/LMWC.2021.3129153.
- [43] C. Zeng, D. J. King, M. Richardson, ir B. Shan, „Fusion of multispectral imagery and spectrometer data in UAV remote sensing“, *Remote Sens (Basel)*, t. 9, nr. 7, liep. 2017, doi: 10.3390/rs9070696.
- [44] T. Chen *ir kt.*, „MXNet: A Flexible and Efficient Machine Learning Library for Heterogeneous Distributed Systems“, gruodž. 2015, [Interaktyvus]. Adresas: <http://arxiv.org/abs/1512.01274>

Priedai

- 1 Priedas.** Pristatytas mokslinis straipsnis 27-oje tarptautinėje informacinių technologijų konferencijoje „IVUS 2022“ **Šidlauskas A.**, Kriščiūnas A. (2022). Pixel-based Forest classification of Sentinel-2 images using automatically generated datasets.
- 2 Priedas.** Paskelbtas mokslinis straipsnis CA WoS duomenų bazėje referuojamame žurnale „Water“ Akstinas V., Kriščiūnas A., **Šidlauskas A.**, Čalnerytė D., Meilutytė-Lukauskienė D., Jakimavičius D., Fyleris T., Nazarenko S., Barauskas R. (2022). Determination of River Hydromorphological Features in Low-Land Rivers from Aerial Imagery and Direct Measurements Using Machine Learning Algorithms.