

Tartu Ülikool
Loodus- ja täppisteaduste valdkond
Ökoloogia ja maateaduste instituut
Geograafia osakond

Magistritöö geoinformaatikas ja kartograafias (30 EAP)

Maastikuelementide tuvastamine kaugseire abil

Nikita Murin

Juhendaja: PhD Evelyn Uuemaa

Tartu 2022

Annotatsioon

Maastikuelementide tuvastamine kaugseire abil

Maastikuelemendid, mis asuvad põllumassiividel või põllumassiivide servades, mängivad olulist rolli looduskeskkonna mitmekesisuse ja elurikkuse tagamisel. Eesti maastikuelementide andmebaasi uuendatakse käsitsi põlluomanike taotluse põhjal. Andmebaas aga tihti ei esinda reaalselt olukorra maastikul, sest paljud maastikuelemendid jäävad andmebaasi sisestamata. See aga piirab maastikuelementide reaalse olukorra hindamist ja maastikuelementide seiret Eestis. Käesoleva töö eesmärk on töötada välja kaugseire meetodid maastikuelementide tuvastamiseks. Arvestades antud töö suurt arvutusmahukust, töötati esimese meetodina välja lihtne ja kiire kaardialgebral põhinev pikslipõhine meetod. Arvutusmahukama ja täpsema meetodina loodi objektipõhise pildianalüüsi töövoog masinõpe abil klassifitseerimisega. Mõlema väljatöötatud meetodiga saavutati üldiselt kõrge klassifitseerimise kogutäpsust, samas kui tootja ja kasutajatäpsused ei olnud nii kõrged. Meetodite tulemuste ja ajakulu põhjal jõuti järeldusele, et kaardialgebra meetod on hea maastikuelementide olemasolu tuvastamise vahend, kuid objektipõhine pildianalüüs sobib paremini maastikuelementide klasside eristamiseks.

Märksõnad: maastikuelemendid, objektipõhine pildianalüüs, avatuse indeks, masinõpe

CERCS kood: T181 Kaugseire

Abstract

Detection of small-scale landscape elements with remote sensing

Landscape elements located on agricultural fields or on their edges play crucial role in the biodiversity of agricultural land. The landscape elements' database in Estonia is updated in accordance with applications of the field owners; and usually it does not represent a real situation of the landscape elements on the field. Hence, the analysis and control over landscape elements are limited. The main aim of this study is to create a methodology to map landscape elements in Estonia with remote sensing data. The first method was created taking into account the importance of computational efficiency and therefore fast and non-complex map algebra solution was developed. The second, more precise but more computationally expensive way to map landscape elements, was object-based image analysis method utilizing machine learning classification. Both methods displayed high overall accuracies, but user's and producer's accuracies were lower. Considering computational time and accuracy, it was concluded that map algebra method is better suitable for fast landscape elements' detection. However, the object-based image analysis method is more suitable for identifying more exact classes of landscape elements.

Keywords: landscape elements, GEOBIA, openness index, machine learning

CERCS code: T181 Remote sensing

Sisukord

Sissejuhatus.....	3
1 Teoreetiline alus.....	4
1.1 Maastikuelemendid	4
1.2 Kaugseire meetodid maastikuelementide kaardistamiseks	6
1.2.1 Objektipõhine pildianalüüs kõrge resolutsiooniga andmetega	7
1.2.2 Masinõppe meetodid kaugseires	8
1.3 Varasemad maastikuelementide kaardistamise tööd.....	8
1.3.1 Maailmas	8
1.3.2 Eestis	10
2 Uurimisala.....	10
3 Andmed ja metoodika	12
3.1 Andmed	12
3.2 Metoodika.....	13
3.2.1 Eeltöötlus	14
3.2.2 Objektipõhine pildianalüüs	18
3.2.3 Tulemuste valideerimine.....	22
4 Tulemused ja arutelu.....	23
4.1 Kaardialgebra	23
4.2 Objektipõhine pildianalüüs	24
4.3 Ajakulu	26
4.4 Tulemustest kokkuvõte	28
4.5 Võimalused tulemuste parandamiseks	30
Kokkuvõte.....	33
Summary	35
Tänuavaldused	37
Kasutatud kirjandus	38
Lisad.....	43

Sissejuhatus

Euroopa Liidu ühise põllumajanduspoliitika üheks suunaks on rohestamine. Põllumajanduse rohestamise tagamise meetmed on erinevad, üks nendest on põldudel maastikuelementide olemasolu (Suure et al., 2021). Maastikuelemendid mängivad suurt rolli maastiku mitmekesisuse tagamisel, suurendades maastiku mitmekesisust ja vähendades nitraatide sattumist veekogudesse. Positiivsele maastikuelementide mõjule viitab ka suurem lindude ja loomade liigirikkus maastikuelementidega põldudel, kuhu loomi meelitavad potentsiaalsed elupaigad ja transiitkoridorid (Maarja et al., 2013; Oja et al., 2016; Zurqani et al., 2020).

Eestis on Põllumajanduse Registrite ja Informatsiooni Amet (PRIA) loonud maastikuelementide andmebaasi. PRIA-s uuendatakse andmebaasi käsitsi põlluomaniku taotluse põhjal ja selle kaudu saab põlluomanik maastikuelemente oma põllumassiivi toetusõigusliku pindala hulka arvestada (Suure et al., 2021). Põlluomanik on aga kohustatud säilitama kõik maastikuelemendid sõltumata elemendi andmebaasis olemasolust. Kaardistamata maastikuelementide seire on raskendatud, sest paljud maastikuelemendid asuvad looduslikult keset põllumassiivi, kuid on administratiivselt erinevate omanike põldude vahel ja selle tõttu pole sellist maastikuelementi andmebaasi sisestatud. Samuti on keeruline tuvastada maastikuelementide kadumist. Ülaltoodud väljendub ka PRIA andmebaasi puudulikkuses reaalse maastikuelementide olukorra osas Eestis ja raskendab maastikuelementide seiret (Oja et al., 2016).

Eesti Topograafia Andmekogu (ETAK) võib teataval määral kasutada potentsiaalsete maastikuelementide tuvastamiseks, aga ETAKi probleemiks on ajakohasus. Seetõttu tuleks kaaluda kaugseire võimalusi andmebaasi ajakohastamisel. Kaugseire lähenemine võimaldab suurtel aladel juba olemasolevate andmete põhjal potentsiaalseid maastikuelemente kaardistada. Võrreldes ETAK-i andmetega, mille vanus mõnes Eesti piirkonnas ulatub 26 aastani, on Maa-ameti LiDAR ja ortofotode vanus on maksimaalselt 4 aastat, mis teeb kaugseire andmete ajakohasuse mõttes palju sobilikumateks. Maa-ameti aerolaserskaneerimise andmetest tuletatud normaliseeritud maakatte (nDSM) mudelit ja ortofotosid on varasemalt Eestis edukalt kasutatud näiteks võsastumise tõttu muutunud põllupiiride tuvastamiseks (Voormansik, 2016). Mujal maailmas on LiDAR andmete ja kõrge resolutsiooniga ortofotode abil sarnaseid maastikuelemente tuvastatud objektipõhise pildianalüüsi meetodil (Jeong et al., 2016; Krause et al., 2011).

Käesoleva töö eesmärgiks on välja töötada kaugseirel põhinev metoodika maastikuelementide tuvastamiseks Maa-ameti kaugseire andmete põhjal, mis võimaldaks hinnata nii reaalselt maastikuelementide olukorda Eestis kui ka seirata maastikuelementide säilimist. Töö käigus võrreldakse omavahel klassifitseerimise täpsuse ja ajakulu alusel objektipõhiseid ja pikslipõhiseid metoodikaid kolmel uurimisalal Eestis: Lõuna-Eestis, Kesk-Eestis ja Saaremaal. Töös püstitati järgmised uurimisküsimused:

- 1) Milline kaugseirel põhinev meetod on kõige kiirem ja milline on kõige täpsem?
- 2) Kas kaugseire abil on võimalik tuvastada erinevaid maastikuelementide klasse?


1 Teoreetiline alus

1.1 Maastikuelemendid

Alates 1962. aastast Euroopa Liidus on käivitatud ühine põllumajanduspoliitika, mis rakendus järk-järgult ning 2015. aastaks ilmus Eestis põllumajandusministri määrus „Maa heas põllumajandus- ja keskkonnaseisundis hoidmise nõuded“ (Riigiteataja, 2015). Määruse üks osa on maastikuelemendid, mis on põllumassiivide „ökoalad“. Nende roll on toetada looduskeskkonna mitmekesisust ja elurikkust. Maastikuelemendid jäävad toetusõiguslike põllumassiivide pindalate hulka ja üle 15 hektarisel põllumassiivil peavad katma vähemalt 5% pindalast. Lisaks sellele, säilitama peab kõike olemasolevaid maastikuelemente, ka siis, kui nad katavad rohkem kui 5% põllumassiivi pindalast (Suure et al., 2021).

Eestis maastikuelementide andmebaasi eest vastutab Põllumajanduse Registrite ja Informatsiooni Amet (PRIA). Euroopa Liidu ühtse põllumajanduspoliitika raames PRIA-s valmis maastikuelementide andmebaas, kuhu kuulub 6 maastikuelemendi tüüpi:

- Põllusaar – 0,01-0,5 ha suurune põllusaar, kus võivad esineda puud, põõsastikud, kivid või muu looduslik taimeistik ning põllusaar on selgesti eristatav ümbritsevast põllumaast (Joonis 1a).
- Metsasiil – minimaalselt 20 m pikkune ja maksimaalselt 30 m laiune metsariba mis on selgesti eristatav ümbritsevast põllumaast. Võib puutuda põllumassiivi piiriga maksimaalselt 30 m ulatuses (Joonis 1b).
- Puude rida – põllumaal või põllu piiril asuv selgesti eristatav puude rida, minimaalse rea pikkusega 20 m ning puude tihedusega minimaalselt 3 puud 20 m kohta (Joonis 1c).
- Hekk – Põllumaal või põllu piiril asuv selgesti eristatav puudega või põõsastega hekk. Minimaalselt 0,01 ha pindalaga ja 20 m pikkune ning maksimaalselt 10 m laiune. Hekis võivad esineda kuni 4 m katkestused (Joonis 1d).
- Kiviaed - Põllumaal või põllumaaga külgneval alal asuv kiviaed, samuti pärandkultuuriobjektina kaardistatud kiviaed. Laius minimaalselt 50 cm ja maksimaalselt 280 cm ning kõrgus minimaalselt 30 cm ja maksimaalselt 170 cm (Joonis 1e).
- Kraav – kuni 10 km² valgalaga eesvoolud ja kuivenduskraavid laiusega kuni 12 m. (Joonis 1f).



Joonis 1 Maastikuelementide näited: a) Pöllusaar. Foto: Maa-amet, 2022c; b) Metsasiil. Foto: Maa-amet, 2022c; c) Puude rida. Foto: Maa-amet, 2022c; d) Hekk. Foto: Maa-amet, 2022c; e) Kiviaed. Foto: Maa-amet, 2022c; f) Kraav. Foto: PRIA, 2021

Hekid on näiteks head maastikuelemendid nitraatide kinnipidamiseks põldude piiridel, mis takistavad toitainete sattumist veekogudesse ja pidurdavad selle kaudu eutrofeerumise arengut veekogudes (Zurqani et al., 2020). Pöllusaared, metsasiilud on olulised lindudele ja loomadele elu- ja transiitaladena (Maarja et al., 2013). Nad suurendavad oluliselt põllu servade pikkust, mis omakorda mõjutab maastiku keerukust ja mitmekesisust (Oja et al., 2016). Talviti on maanteedel märkimisväärne probleem tugeva tuulega ilma puhul, kui suurte põldude läbivate teede peale tekkivad läbimatud lumevallid. Hekid või puude read võivad olla head tuule- ja lumetõked ning teha Eesti teed natuke ohutumaks talvisel ajal.

Käesolevas töös kiviaedasad ei tuvastata, sest nende kõrgus tihtipeale on alla 2 m, aga Maa-ameti maakatte kõrgusmudelil on kõik alla 2 m objektid välja jäetud ega maapinna kõrgusmudelil need pole tavaliselt tuvastatavad. Teiseks, suur osa kiviaedadest asub puuvõrade all, mis ei võimalda neid eristada teistest reljeefi vormidest optiliste andmete abil.

Andmebaasi uuendatakse käsitsi jooksvalt põlluomanikke taotluse alusel PRIA-s või põlluomanikud sisestavad maastikuelemente iseseisvalt PRIA e-teeninduses. Enne taotluse lõpliku esitamist registri ametnikud kontrollivad sisestatud maastikuelementide asjakohasust üle (Suure et al., 2021). Süsteemil, kus maastikuelemente sisestatakse andmebaasi põlluomaniku taotluse põhjal, on omad kitsaskohad.

Vaatamata sellele, et andmebaasi pidevalt uuendatakse, mõnikord ei ole kõik maastikuelemendid isegi ühe põllumassiivi piires andmebaasi sisestatud. Esiteks, põlluomanikule on kohustuslik jätta 5% põllumassiivi pindalast maastikuelementidena välja vaid üle 15 hektaristel põllumassiividel, mis tähendab et väiksemate põldude maastikuelemendid jäävad sageli andmebaasi sisestamata. Ka need maastikuelemendid, mis asuvad üle 15 hektaristel põllumassiividel võivad mõnikord andmebaasi sisestamata jääda, kui kohustuslikud 5% on täidetud teiste maastikuelementide pindalaga sama põllumassiivi piires.

2016. aastal Tartu Ülikooli Geograafia osakonna poolt läbi viidud uuringus selgus, et Eestis on Pandivere kõrgustikul, mis on ka ühtlasi intensiivne põllumajandus piirkond, on maastikuelemente vähe. Pärnumaal ja Tartumaal oli maastikuelementide osakaal põllumassiividest suurim Eestis. Uuringus oli kasutatud PRIA maastikuelementide andmebaas ja selle täienduseks ETAK-i andmetest koostatud potentsiaalsete maastikuelementide kiht. ETAK-i kihist oli lisatud suur hulk potentsiaalseid maastikuelemente (Oja et al., 2016), kuid nende andmete ajakohasus on mõnedes piirkondades kahtlane, sest andmete vanus ületab mõnikord 20 aastat (Maa-amet, 2022b).

1.2 Kaugseire meetodid maastikuelementide kaardistamiseks

Satelliitide abil kaugseire leidis laia kasutuse maailmas väga mitmekesiste eesmärkide täitmiseks siis, kui 1972. aastal saadeti orbiidile esimese tsiviilotstarbega maad pildistava satelliidi Landsat-1. Kõige levinumateks andmeteks said keskmise ruumilise lahutusega pildid: 10 m – 30 m piksli suurusega. Kaugseire andmete kasutamine on efektiivne metsanduses, maakasutuse planeerimises või põllumajanduses kasutamiseks (Peterson et al., 2008). Selliste andmete klassifitseerimiseks kasutatakse tavaliselt pikslipõhist pildianalüüsi, sest objektid (põllud, metsamassiivid) on palju suuremad, kui üksik piksel pildil, olles samal ajal homogeensed.

Pikslipõhine pildianalüüs toimib kõige paremini spektraalselt homogeensete alade puhul, näiteks mets või põld. Heterogeensete alade puhul nagu hõre mets või asustatud alad tulevad esile pikslipõhise pildianalüüsi nõrkused (Riggan ja Weih, 2009). Pikslipõhise meetodi peamine nõrkus on fikseeritud väikseima kaardistusühiku suurus - piksel. Pikslipõhiste meetodite rakendamise tulemusena saadakse tihti kaugelt vaadates hästi klassifitseeritud pilt, kuid suurendades on näha „soola-pipra“ efekti. See väljendub üksikutes valesti klassifitseeritud pikslites üldiselt õigesse klassi klassifitseeritud pikslite vahel. Näiteks Austraalia savannide kaardistamisel, mis omavad katkendliku iseloomu tulekahjude tõttu ja hõredalt kasvavate puudega (Whiteside et al. 2011).

Kaugseire aga ei toetu ainult keskmise ruumilise lahutusega satelliitide andmetele. Nendele on hiljem lisandunud nii kõrge ruumilise lahutusega satelliitpildid teistelt satelliitprogrammidelt (IKONOS, QuickBird, GeoEye-1) kui ka lennukitelt saadud ortofotod (neid kasutati ka enne 1972) ja laserskannerite andmed (Blaschke, 2010; Maa-amet, 2022a; Peterson et al., 2008). Sellised andmed võimaldavad teostada väiksemate objektide kaugseiret, sealhulgas ka maastikuelementide suuruste objektide tuvastamist. Kaugseire rakendustes, kus otsitava või kaardistatava objekti suurus oluliselt ületab piksli suurust, kasutatakse enamasti objektipõhist pildianalüüsi. Objektipõhise pildianalüüsi eelis pikslipõhise pildianalüüsi ees on väikseima kaardistusühiku paindlik valik – alguses eristatakse objektide piirid ja seejärel neid klassifitseeritakse. Kui piiritletud objekti kirjeldab terve hulk piksleid, siis üksiku piksli väärtused ei esinda enam terve objekti omadusi. Pikslid hakkavad kirjeldama sellel juhul objekti heterogeensust ja tekstuuri statistiliste näitajate põhjal. Objektil ehk pikslite kogumil on lisaks spektraalsetele omadustele ka kuju ja suurust kirjeldavad omadused. Austraalia savannide näitel võimaldab objektipõhine pildianalüüs piiritleda maakatte tüübid paremini ja tulemustes puudub soola-pipra efekt (Blaschke, 2010; Kucharczyk et al., 2020; Riggan ja Weih, 2009; Whiteside et al. 2011).

1.2.1 Objektipõhine pildianalüüs kõrge resolutsiooniga andmetega

Objektipõhine pildianalüüs põhineb inimese aju pildi tajumise protsessidel. Inimene, kes vaatab pilti, alguses eristab pildil objekte, seejärel, kui objektid pildil on piiritletud, neid hakatakse grupeerima omavahel arvestades omadusi ja konteksti. Grupeerimine toimub meie ajus keeruliste neurovõrkude abil, mis on treenitud inimese kogemusega ja teadmistega. Järelikult on esimene ja väga oluline etapp objektipõhises pildianalüüsis pildi segmenteerimine (Blaschke et al., 2000; Sébastien et al., 2019). Segmenteerimisel arvestatakse pildi homogeensust, objektide suurust ja kuju, pildi ruumilist lahutust ning segmenteerimise algoritmist tulenevaid seadistatavaid parameetreid.

Kui andmekihthe on mitu ja nende omadused erinevad teineteisest, siis andmeid tuleb omavahel kokku sulatada (*data fusion*). Sellel on kolm lahendust: 1) panna andmekomplekt kokku enne segmenteerimist ehk piksli tasemel; 2) panna kokku segmendid enne klassifitseerimist ehk objektide tasemel; 3) panna kokku juba klassifitseeritud segmendid (Sébastien et al., 2019).

Tänaseks on välja töötatud suur hulk erinevaid lahendusi, kuid universaalset lahendust, mis ei nõuaks parameetrite seadistamist, ei ole. Lahendus sõltub väga palju tuvastatavate objektide iseloomust – suurus, kuju, tekstuur jms.

Segmenteerimise ja klassifitseerimise tarkvarast kõige tuntum kommertstarkvara on eCognition (Trimble Germany GmbH, 2021). Alternatiivina on tänapäeval mitmed lahendused avatud koodiga, mis on kasutajale tasuta, neid on mõnevõrra raskem kasutada, kuid asjatundjal on võimalus ka lähtekoodi modifitseerida kindla ülesanne jaoks. Üks avatud koodiga lahendus on Orfeo Toolbox (OTB) (Grizonnet et al., 2017), mis sisaldab mitmeid segmenteerimisalgoritme ja klassifitkaatoreid. OTB on C++ moodul, mis on välja arendatud Prantsuse Kosmose Agentuuri (CNES) poolt ja on nüüdseks integreeritud ka QGISi.

Segmenteerimise lahendused võib jagada kahte gruppi: 1) ülevalt-alla; ja 2) alt-ülesse. Ülevalt-alla algoritmid alustavad ühe suure segmendiga ja jagavad seda väiksemateks objektideks kuni

need hakkavad vastama seadistatud kriteeriumitele. Alt-ülesse algoritmid vastupidi kasvatavad pikslite kogumit alustades ühest pikslist. Tavaliselt segmenteerimise meetodi parameetrid on pikslite spektraalne sarnasus, objekti kuju ja objekti suurus (Shepherd et al., 2019).

1.2.2 Masinõppe meetodid kaugseires

Masinõpet kasutatakse nii pikslipõhiste kui ka objektipõhiste meetodite puhul ning enamasti annavad nad klassifitseerimisel edukamaid tulemusi kui meetodid, kus reegleid luuakse käsitsi. Masinõppe tehnikaid on suur hulk:

- 1) K-lähima naabri meetod. Klassifitseerimise algoritm, mis põhineb nii öelda „enamuse hääletamisel“. Objekti klassifitseeritakse tunnuste poolest lähimate õpetusnäidiste põhjal sellisse klassi, mille õpetusnäidiste esindajaid on naabruskonnas kõige rohkem. Algoritmi kasutamisel saab seadistada lähimate naabrite arvu, mille seas toimub „hääletamine“. Algoritmi tugev külg on lihtsus. Puuduseks on aga andmemahu suurendamisega kiirelt kasvav arvutusmaht ja klassifitseerimistäpsuse sõltuvus õigest naabrite arvu valikust (IBM, 2022);
- 2) otsustuspuude koostamisel põhinevad tehnikad, näiteks juhuslik mets (*random forest*). Tööpõhimõtte on juhuslikust klassifitseerimisest natuke paremate otsustuspuude kombineerimise teel konstrueerida üks „otsustuspuude mets“ kõrge klassifitseerimise täpsusega. Juhusliku metsa algoritmi kasutamisel saab seadistada kaks olulisemat parameetrit: puude arvu ning juhuslikult valitavate tunnuste ja vaatluste arvu ühes otsustuspuus (Shahab et al., 2019; Sheykhnousa et al., 2020);
- 3) tugivektormasinad otsivad õpetusalade tunnuste vahel eralduspiiri, mis asub kummagi klassi omadustest võimalikult kaugel (Voormansik, 2016). Klasside vaheline eralduspiir (kernel) võib olla lineaarne, sigmoid, radiaalne baasfunktsioon või polünoomiaalne. Meetodi eeliseks on suhteliselt väike nõudlus õpetusalade kogusele ning väike tundlikkus andmete jaotusele ja andmetes esinevatele äärmustele. Puuduseks on keerukas kerneli ja selle parameetrite valik ning algoritmi ruutkeerukus, mis tähendab andmehulga X korda suurenemisel treenimise aja X^2 korda kasvamist (Cervantes et al., 2020; Sheykhnousa et al., 2020);
- 4) süvaõppe meetodid (tehisnärvivõrgud) kasutavad keerulised võrgud vähemalt kolme neuroonide kihtidega ja kaaludega neuroonide kihtide vahel. Tehisnärvivõrkude resurssimahukaim protsess on võrgu õpetamine, mis toimub iteratiivselt kaalude kohandamisega õige tulemuse suunas ning vajab suure hulga õpetusnäidiseid. See mõjutab ka süvaõppe meetodite kasutamist geograafilises objektipõhises pildianalüüsis (Shahab et al., 2019).

1.3 Varasemad maastikuelementide kaardistamise tööd

1.3.1 Maailmas

Eelmainitud maastikuelementide mõõtmetes objektide tuvastamist või kaardistamist on uuritud palju. Enamasti kasutatakse sel juhul kõrge ruumilise lahutusega andmeid nagu ortofotod (Kollar et al., 2013), LiDAR andmeid (Lucas et al., 2019) või nende kombineerimist (Jeong et al., 2016; Krause et al., 2011; MacFaden et al., 2012; O'Neil-Dunne et al., 2014; Zuhani et al., 2020).

Metoodikaid võib jagada kahte gruppi: 1) käsitsi klassifitseerimisreeglite loomine; 2) erinevaid masinõppe algoritme kasutatavad metoodikad.

Sentinel-i kasutamise võimalused väikeste maastikuelementide seiramisel on mõnevõrra piiratud kuna Sentineli piksli suurus on kohati liiga suur (10 m), et tuvastada kitsamaid kraave ja väikseid põllusaari. Kaugseire reeglite kohaselt piksli suurus olema vähemalt kaks korda väiksem kui tuvastatav objekt. Radoux et al. (2016) leidis, et üks oluline aspekt pikslist väiksema suurusega objektide eristamiseks ümbritsevast homogeenest maastikust on nende spektraalne erinevus ümbritsevast maast. Radoux et al. (2016) tööst selgus, et väikeste objektide tuvastamine Sentinel-2 andmete põhjal tugevalt sõltub sellest, milline on objekti ümbritsev keskkond

Näiteks lineaarsed taimestikust maastikuelemendid, mida on võimalik Sentinel-2 andmete kaudu tuvastada, on tuvastatavad, kui nende laius on vähemalt 6-7 m ja nad on ümbritsetud küntud maaga. Kui samasugused maastikuelemendid on ümbritsetud põllukultuuridega, siis minimaalne tuvastatav laius on juba 14-16 m. Sellest tulenevalt ei ole maastikuelementide tuvastamine ainult Sentinel-2 andmete põhjal realistlik ning seetõttu Sentineli andmeid käesolevas töös ei kasutatud.

Krause et al. (2011) kirjeldasid Hollandi põllumajandusuuringute teenistuse sihtasutuse aruannes metoodikat, kuidas väikeseid maastikuelemente tuvastada LiDAR ja ortofoto andmete kombineerimisel. Nende metoodika tugines maakate kõrgusmudeli põhjal loodud segmentide klassifitseerimisel, kus segmenteeritud kõrgusmudelile hiljem lisandus ortofotodest tuletatud NDVI andmed ja väljatöötatud reeglite põhjal klassifitseeriti segmentid maastikuelementide tüüpidesse. Järgmise sammuna ühendati kõrvalolevad segmentid sarnaste omadustega ühte objekti ning objekti kuju omaduste põhjal eristati ka lineaarsed ja mitte-lineaarsed objektid. Prooviaala oli kaetud ainult põllumaaga harva esinevate väikeste hoonestusaladega. Töös oli katsetatud ka kraavide tuvastamist, tehes seda DEM mudeli põhjal. Prooviaala oli väga väike ning tasane, seega DEM mudel tõesti kirjeldas kraavide piirid hästi.

Veel ühte detailset ala kaardistamist viisid läbi Jeong et al. (2016). aastal Lõuna-Koreas. Kaardistamise alaks oli liigirikas jõe kaldaäärne ala, mida jagati 10 klassi. Metoodikas kasutati LiDAR andmeid ja ortofotosid, mille põhjal viidi läbi eCognition tarkvaras *Multiresolution Segmentation* algoritmiga segmenteerimist ning segmentid jagati klassidesse samuti käsitsi loodud reeglite põhjal. Autorid rõhutasid segmenteerimise olulisele rollile ning segmenteerimise parameetrite leidmisele katse ja eksituse meetodil. Kogutäpsuseks määrati 88,2% ja kapa koefitsiendiks 0,86, mis on kõrgem kui varasemad katsetused sarnaste alade kaardistamisel.

Teine laialt kasutatav metoodika on masinõppe kasutamine. Lucas et al. (2019) kasutasid lineaarsete maastikuelementide tuvastamiseks ainult LiDARi punktipilve. Nad eemaldasid tasapinnad, seejärel klassifitseerisid juhusliku metsa abil punktipilve taimestikuga ja taimestikuta alaks ning rakendasid piirkonna-kasvatatava (*region growing process*) algoritmi, mis tugines piirkonna riistküülikususe (*rectangularity*) omadusele, klassifitseerisid lineaarseid maastikuelemente.

O'Neil-Dunne et al. (2014) ja MacFaden et al. (2012) uurisid puude tuvastamist asustatud aladel kasutades objektipõhist pildianalüüsi ning tuginedes andmetele, millesse oli juba varem investeeritud kohalike valitsuste poolt - LiDAR, ortofoto ja GIS kihid. Nendes töödes põhilised

andmed olid LiDAR-ist tuletatud kõrgusmodelid ja taimeistiku eristamiseks tehisojektidest ortofotod ja GIS kihid. Klassifitseerimine toimus ekspertide poolt välja töötatud reeglite põhjal, mis nõudsid palju katsetamist ning tuginesid segmentide statistilistele näitajatele.

Objektipõhise pildianalüüsi tarkvaraks kasutatakse tihti eCognition tarkvara (Jeong et al. 2016; Kollar et al., 2013; MacFaden et al., 2012; O'Neil-Dunne et al. 2014; Voormansik, 2016), mis on tasuline tarkvara, kuid seevastu pakub kasutajasõbraliku keskkonna, võimalust kasutada nii reeglipõhist (MacFaden et al., 2012) kui ka masinõppe algoritme (Voormansik, 2016) ning võimalusi töötada suurte andmete kogustega (O'Neil-Dunne et al. 2014).

Viimasel aastakümnel on hakatud kasutama ka tehisnärvivõrke objektipõhises pildianalüüsis. Tulemuste täpsus on tavaliselt natuke kõrgem, võrreldes klassikalisemate masinõppe algoritmidega (nt. juhuslik mets või tugivektormasin). Tehisnärvivõrkude puuduseks võrreldes eelmainitud algoritmidega on suurema treeningandmete koguse vajadus, pikk mudeli treenimise aeg, seadistatavate parameetrite keerukus ning peidetud loogika (kus protsess on juhitav numbritega iseseisvalt ning ei ole inimese kontrolli all, nii nimetatakse „*Black box*“) (Kucharczyk et al., 2020; Zhao et al., 2017).

1.3.2 Eestis

Detailse kaardistuse jaoks leiavad Eestis tihti kasutust Maa-ameti andmed ning meetodina on kasutatud objektipõhist pildianalüüsi (Tamm et al, 2014; Voormansik, 2016).

Metoodilise uuringu sarnasel temaatikal Eestis on läbi viinud Voormansik (2016) omas magistritöös. Eesmärgiks oli võsastumise tõttu põllupiiride muutmise tuvastamine. Selleks kasutati Maa-ameti arendatud tooted: kõrgusmodel nDSM ruumilise lahutusega 1 m ja metsanduslik ortofoto piksli suurusega 0,25 m. Metoodikaks oli valitud objektipõhine pildianalüüs tugivektormasina klassifitseerimisega. Üks töö eesmärk oli võrrelda ainult nDSM ja nDSM + ortofoto tulemusi. Tuli välja, et klassifitseerimistäpsus oli mõlemal juhul kõrge – kogutäpsused 96% ja 97% ning kapp koefitsiendid 0,91 ja 0,92.


Tamm et al. (2014). aastal kasutades Maa-ameti poolt toodetavad andmed hindasid segmenteerimise ja tugivektormasina klassifitseerimise rakendatavust Eestis maakattetüüpide kaugseires. Parima täpsuse saadi metsa ja põõsastiku tuvastamisel, kus kasutajatäpsus oli 97% ja kapp koefitsient 0,85.

Rist (2017) uuris omas magistritöös droonifotode abil soode objektipõhist klassifitseerimise võimalusi e-Cognition ja QGIS tarkvarades, kusjuures kasutati nii ainult aerofotosid kui ka aerofotode ja kõrgusmodelite kombinatsiooni. Töös kasutati võrdluseks näidisteta ja pikslipõhiseid klassifitseerimisi. Näidisteta klassifitseerimine ei andnud väga häid tulemusi, aga parim tulemus (kogutäpsus 68%) saavutati objektipõhise pildianalüüsi ja k-lähima naabri algortimiga.


2 Uurimisala

Uurimisalaks valiti kuus 1:10 000 kaardilehte kolmest Eestile iseloomulikust maastikust paaridena – üks kaardileht treenimiseks ja teine kaardileht ennustuse valideerimiseks. Kaardilehed on jaotatud erinevate Eestile iseloomulike maastike vahel. Kaardilehed 54144 ja 54184 (Joonis 2, 3e, 3f) asuvad Lõuna-Eestis, kus maastik ja reljeef on kõige mitmekesisemad Eestis. Kaardilehed

63342 ja 63462 (Joonis 2, 3c, 3d) on valitud iseloomustamiseks Kesk-Eesti intensiivsemate põllumajandusmaade maastiku. Kaardilehed 52743 ja 52824 (Joonis 2, 3a, 3b) asuvad Saaremaal ja iseloomustavad saarte ja Lääne-Eesti tasast maastiku. Kaardiruutude valik teostati maastikuelementide koguse ja mitmekesisuse ning põllumaa pindala järgi.



Joonis 2 Uurimisalade asukohad Eestis



Joonis 3 Uurimisalade näited metsandusliku ortofoto taustaga. Kollasega tähistatud PRIA maastikuelemendid

3 Andmed ja metoodika

3.1 Andmed

Töös kasutati Maa-ameti poolt toodetud maapinna kõrgusmudelit (DEM), normaliseeritud maakatte kõrgusmudelit (nDSM) ja metsanduslikku ortofotot. Vektorandmetest kasutati PRIA maastikuelementide (kirjeldatud peatükis 1.1) ja põllumassiivide kihte ning Eesti Topograafia Andmekogu (ETAK) ehitiste ja kõlvikute andmekihist puittaimestiku klassi.

Mõlemad kõrgusmudelid on toodetud Maa-ametis aerolaserskaneerimise andmete põhjal. Alates 2017. aastast kasutab Maa-amet LiDAR punktipilve saamiseks aerolaserskannerit Riegl VQ-1560i. Maapinna kõrgusmudel on tuletatud LiDAR punktipilve maapinnaks klassifitseeritud punktidest ja interpoleeritud rastriteks piksli suurusega 1, 5 ja 10 m. Esimesteks peegeldusteks klassifitseeritud punktidest koostatakse maakatte kõrgusmudel ruumilise lahutusega 1 ja 5 m ning normaliseeritud maakatte kõrgusmudeli saamiseks lahutatakse maapinna kõrgusmudel. Normaliseeritud maakatte kõrgusmudelist on eemaldatud kõik objektid, mille kõrgus on alla 2 meetri (Maa-amet, 2022d). Töös kasutatud kõrgusmudelite ruumiline lahutus on 1 m.

Metsanduslikud ortofotod on tehtud aerokaameraga Leica ADS100-SH100, mis salvestab lähisinfrapuna (NIR, 808-882 nm), punase (R, 619-651 nm), roheline (G, 525-585 nm) ja sinise (B, 435-495 nm) kanaleid. Metsanduslikud ortofotod on tehtud lehtpuude lehes oleku perioodil ruumilise lahutusega 25 cm. Uute ortofotodega kaetakse aastas umbes pool Eesti territooriumit (Maa-amet, 2022e).

Uurimisalade paiknemine üle Eestit tähendab, et andmete vanus sõltuvalt uurimisalast on erinev (Tabel 1), aga antud töö on fokuseeritud metoodika välja töötamisele ning vajadusel saab uuemaid andmeid kasutada sama metoodikaga.

Tabel 1 Kaardiruutude kõrgusmudelite ja ortofoto andmete vanus (Maa-amet, 2022d)

Kaardiruut	DEM	nDSM	Metsanduslik ortofoto
52824 (Saaremaa)	2017	2019	2019
52743 (Saaremaa)	2017	2019	2019
63461 (Kesk-Eesti)	2020	2018	2018
63342 (Kesk-Eesti)	2020	2018	2018
54184 (Lõuna-Eesti)	2019	2017	2017
54144 (Lõuna-Eesti)	2019	2017	2017

Metsanduslikest ortofotodest tuletati normaliseeritud taimkatte indeks (NDVI):

$$NDVI = \frac{NIR - R}{NIR + R}$$

NDVI indeks näitab infrapunase (mille suurema osa terve taimeistik peegeldab) ja punase (mille suurema osa terve taimeistik neelab) spektri osa erinevust (GISGeography, 2022).

PRIA põllumassiivide kiht sisaldab kõiki põllumassiive, millele on taotletud pindalatoetusi viimaste kahe aasta jooksul (PRIA, 2021)(Joonis 4).

ETAK-i ehitiste andmekihist kasutati hoonete, kõrgrajatiste, muude rajatiste, maa-aluste ehitiste ja piirete klasse. ETAK-i ehitiste andmekihi vanimad andmed on aastast 2015, suurim osa Eestist on uuendatud alates 2018 aastast (Maa-amet, 2022b)(Joonis 4).

ETAK-i kõlvikute andmekihist kasutati puittaimestiku klassi kuulub ETAK-i kõlvikute gruppi (Joonis 4). Saaremaa kõlvikute kiht oli uuendatud aastal 2015. Kaardiruut valideerimiseks Kesk-Eestist 63461 uuendati aastal 2014 ja kaardiruut Lõuna-Eestist 54184 uuendati aastal 2003 (Maa-amet, 2022b).



Joonis 4 Väljavõte PRIA põllumassiivide, ETAK-i ehitiste ja puittaimestiku kihtidest metsandusliku ortofoto taustal

3.2 Metoodika

Varasemate uuringute põhjal otsustati antud ülesande jaoks valida objektipõhine pildianalüüs. See võimaldab objekte paremini piiritleda ja klassifitseerida objekte rohkematesse klassidesse. Lisaks võimaldab see lahti saada pikslipõhise lähenemisele iseloomulikust soola-pipra efektist. Puuduseks on suurema arvutusressurssi vajadus ja keeruline parameetrite seadistamine. Seega otsustati lisada võrdluseks kaardialgebra pikslipõhine lahendus, mis on palju kiirem ja ressursi suhtes vähe nõudlik.

3.2.1 Eeltöötlus

Mõlema meetodi puhul oli vajalik maapinna kõrgusmudeli eeltöötlus, kuna tuvastatavate maastikuelementide hulka kuuluvad ka kraavid. Nende tuvastamise puhul on oluline leida pinnavormi erisus ümbritsevast alast ka ebatasase reljeefi puhul, mis on iseloomulik näiteks Lõuna-Eestile. Väga tasase reljeefi puhul väikese uurimisala piires selle jaoks piisaks ainult maapinna kõrgusmudelist, kuid üle Eestit see ei ole võimalik suurte maapinna kõrguste vahede tõttu.

Kraavide esile tõstmiseks kasutati järgmisi indekseid, mis arvutati maapinna kõrgusmudelile:


- nõlvakalle (*slope*) – pikslite väärtused kraavide keskel on tasase maapinnaga sarnased, mis raskendab segmenteerimist või muul viisil kraavide põhja kaasamist kraavi segmentidesse
- pikisuunaline kumerus (*longitudinal curvature*) – eristab kraave, kuid selle põhjal on raske kraavi eristada, kuna indeks näitab nii kraavi põhja nõgusust kui ka kraavi servade kumerust
- minimaalne, maksimaalne kumerus (*minimum, maximum curvatures*) – sarnaselt pikisuunalise kumerusega eristab nõgusad ja kumerad kraavide osad eraldi, mis ei esinda kraavide piire
- oru sügavus (*valley depth*) ja avatuse indeks (*topographic openness indeks*) – mõlemad kirjeldavad hästi kraavide piire, kuid avatuse indeksi arvutamine võtab vähem aega. Kasutades „*ridge level*“ parameetri 2 arvutamine võtab aega 110 sekundit, mis võrreldes avatuse indeksi arvutamisega üle 3 korda kauem (kauguse parameetri 10 m puhul 30 sekundit).

Nõlvakalle (slope) ja kumerus (curvature)

Nõlvakalle näitab maksimaalse maapinna gradiendi ja matemaatiliselt on arvutatud kasutades maapinna kõrgusmudeli esimest tuletist. Maapinna pikisuunaline kumerus illustreerib profiili kumerust, mis tekib ristumiskohas maapinna ja tasapinna vahel, mis on defineeritud maapinna normaaliga ja maksimaalse nõlvakaldega. Maksimaalne kumerus on arvutatud igas suunas, minimaalne kumerus arvutatakse perpendikulaarselt maksimaalse kumeruse suunale (Conrad et al., 2015).

Topograafiline avatuse indeks (Topographic Openness Index)

Yokoyama et al. (2002) töötasid välja avatuse indeksi (*Topographic Openness Index*), mis algselt oli mõeldud reljeefi visualiseerimiseks, aga antud töös kasutati seda kraavide tuvastamiseks ning nende piiritlemiseks. Avatuse indeks näitab kui palju ümbritsevat maastiku on näha igast maastiku punktist. Avatuse indeksi arvutatakse 8 suunas (QGIS-i SAGA moodul võimaldab valida ka suundade arvu) iga piksli jaoks. Teine oluline parameeter on radiaalne piir, mis tähendab kaugust arvutatavast pikslist (Joonised 5, 6).




Joonis 5 Avatususe indeksi arvutamine erinevates suundades, kus D on asimuut, L on radiaalne piir, keskel asub piksel, mille avatususe väärtust arvutatakse (Yokoyama et al., 2002)

Avatususe valemid 8 suuna jaoks on järgmised:


$\Phi_L = (\Phi_{L,0} + \Phi_{L,45} + \dots + \Phi_{L,315}) / 8$, kus $\Phi_{L,n}$ on punkti positiivne avatus radiaalse piiriga L konkreetses asimuudi suunas n

$\Psi_L = (\Psi_{L,0} + \Psi_{L,45} + \dots + \Psi_{L,315}) / 8$, kus $\Psi_{L,n}$ on punkti negatiivne avatus radiaalse piiriga L konkreetses asimuudi suunas n



Joonis 6 Positiivne (vasakul), ja negatiivne (paremal) avatus, kus L on radiaalne piir (Yokoyama et al., 2002)

Joonisel 7 on näha, kuidas eristuvad väikesed pinnavormid avatususe indeksi pildil võrreldes tavalise kõrgusmudeliga. Algoritmi radiaalse piiri muutmisega saab võimendada erineva mastaabiga objekte: antud töös radiaalseks piiriks oli valitud 10 m, mis võimendab väikseid objekte nagu kraavid ja tasandab reljeefist tulenevaid ebatasasusi. Suurendades radiaalse piiri tulevad esile ka suuremate pinnavormide nõgusused ja kumerused.



Joonis 7 Väljavõtte kaardiruudust 54184, kus vasakul on 1m DEM mudel ning paremal topograafilise avatususe indeksi positiivne väljund radiaalse piiriga 10

Algoritmi väljundi mõõtühikuks on radiaanid või kraadid seniidist, tasase pinna puhul (sõltumata sellest, kas pind on horisontaalne või nurga all) 90 kraadi või $\sim 1,57$ radiaani (Doneus, 2013).

Oru sügavus (Valley depth)

Alternatiivina kraavide võimendamiseks maapinna kõrgusmudelist kasutati oru sügavuse algoritmi SAGA-st (Conrad et al., 2015). SAGA tarkvaras *valley depth* algoritmi abil oru sügavuse rastri luuakse lahutades maapinna kõrgusmudeli interpoleeritud harja taseme rastrist. Harja taseme rastri saab Stahleri meetodil.


Kaardialgebra

Kõige lihtsama loogika järgi saab kaardialgebra võtetega filtreerida kõrgusmudelite piksleid sellisel viisil, et kaardil jääksid ainult pikslid taimestikuga ja kraavidega. Üleliigsete metsa ja asustatud alade pikslitest lahti saamiseks saab kasutada PRIA põllumassiivide kihi. Maa-ameti normaliseeritud maakatte kõrgusmudeli sisse jäävad kõik objektid, mis on kõrgemad kui 2 m, sealhulgas hooned. Hooned saab eemaldada ETAK-i hoonete kihi abil, korrutades invertteeritud hoonete maski leitud rastriga. Kõik kasutatud ja loodud rastrid on ruumilise lahutusega 1 m.


Maskide ettevalmistamine:

- **Põllumassiivide mask** – loodi PRIA põllumassiivide kihi põhjal. Põllumassiividele loodi 15 m puhver, et oleks võimalik tuvastada kõik kraavid või hekid, mis asuvad põllu piiril ja on PRIA põllumassiividest välja digitud (Joonis 8a). Mõlemalt poolt põllumassiividega ümbritsetud metsasiilude tuvastamiseks piisab samuti 15 m põllumassiivide puhvrist, sest PRIA andmebaasis on metsasiilud defineeritud laiuse parameetriga kuni 30 m. Põllusaared on samuti osaliselt põllumassiividest välja lõigatud. Seejärel põllumassiivide maski konverteeriti rastriks, kus väärtus 1 omistati põllumassiividele ning 0 ülejäänule.
- **Maakatte mask** – Maa-ameti normaliseeritud maakatte kõrgusmudelis (nDSM) on kajastatud ainult objektid, mis on kõrgemad kui 2 m maapinnast. Maski tegemiseks omistati kõikidele pikslitele, mis on maapinnast kõrgemad, väärtus 1, ülejäänutele 0 (Joonis 8b).
- **Ehitiste mask** – kuna nDSM sisaldab kõiki objekte, mis on maapinnast 2 m kõrgemad, siis neid tuleb maksimaalselt tulemustest filtreerida. Suurem osa mitte-taimestiku piksleid nDSM mudelis on hooned. Ehitiste andmestiku hulka kuuluvad hooned, kasvuhooned, katusealused ja muud ehitised. Nendest koostati invertteeritud mask, kus ehitiste väärtus rastril on 0 ja ülejäänud maa väärtus on 1 (Joonis 8c).
- **Kraavide mask** – avatuse indeksi histogrammi põhjal leiti, et lävend 1.5 radiaani võimaldab eristada ka väikesed kraavid, mis mõnikord kaartidel puuduvad ja sellepärast vajavad rohkem tähelepanu. Väikeste kraavide sisse toomisega suureneb ka lävendi järgi sobivate pikslite esinemine põllusaartel ja muudes kohtades, kus esinevad väikesed pinnavormid, aga antud töös otsustati maksimaalne kraavide tuvastamine seada prioriteediks. Seega valmis kraavide mask, kus positiivse avatuse indeksi väärtused (ehk potentsiaalsed kraavid) alla 1,5 radiaani on 1 ning tasane pind on 0. ETAK-i ehitiste hulka kuuluvad ka joonobjektidena piirde, mis on üheks valepositiivsete kraavide allikaks, kuna kõrge piire kõrval on avatuse indeks alla 1,5 radiaani. Piiretele lisati 5 m puhver mõlemale poole ning konverteeriti invertteeritud rastriks, seejärel korrutati kraavide maskiga ning tulemuseks saadi puhastatud kraavide mask (Joonis 9). See protseduur viidi läbi maski

valmistamise käigus, sest lõpptulemuse piiretega maskimine eemaldaks ka taimestikuks klassifitseeritud pikslid.



Joonis 8 Maskide näided. a) Põllumassiivide kihi võrdlus pugvriga ja ilma; b) Maakatte mask; c) Ehitiste inverteeritud mask




Joonis 9 Kraavide maski puhastamine piiiretest tingitud valepositiivsetest pikslitest. Vasakpoolsel pildil on kraavide mask enne puhastamist, kus tumesinisega on näidatud pikslid, mida eemaldati piirete maskiga ning helesinised jäävad alles; kollasega on näidatud piirded. Paremal pool on kraavide mask pärast puhastamist. Taustaks topograafiline avatuse indeks, kus tumedamad alad on väiksemate avatuse indeksi väärtustega.

Järgmise etapina viidi läbi kaardialgebra, mille eesmärk oli saada 4 klassi: kraav, kraav taimestikuga, taimestik ning puhas ala. Selleks kasutati järgmist tehet:

$(\text{Maakatte mask} \times \text{Kraavide mask} + \text{Kraavide mask} + \text{Maakatte mask} \times 2) \times \text{Põllumassiivide mask} \times \text{Ehitiste mask}$

Sellele viidi läbi mürapikslite puhastamine „sõelaga“ (Sieve), mis eemaldas kõik etteantud lävendist väiksemad pikslite grupid asendades neid suurima kõrvuti asuva pikslite grupi väärtusega (Joonis 10).



Joonis 10 "Sõela" kasutamise tulemus. Toore kaardialgebra tulemus vasakul ja "sõelutud" tulemus paremal

3.2.2 Objektipõhine pildianalüüs

Objektipõhise analüüsi olulised sammud on segmenteerimine ja klassifitseerimine. Antud töös segmenteerimise tulemusi ja esimese etapi klassifitseerimise tulemusi hinnati visuaalselt. Segmenteerimise puhul vaadati segmentide piiride vastavust maastikus olevate objektide piiridele ning segmentide korrektset olemasolu maastikuelementide kohal. Klassifitseerimise tulemust hinnati klasside õigsuse põhjal, kus oli eriti oluline, et põllu ja potentsiaalsete maastikuelementide klasside vahel ei oleks valesti klassifitseeritud segmente. Objektipõhise pildianalüüsi meetodit katsetati kahe ja kolme kanali andmekomplektidega, kusjuures nende vahel töövoogud erinesid veidikene (vt allpool). Sarnaselt Krause et al. (2011) tööga koosnes objektipõhine pildianalüüs kahest etapist: spektraalsete omaduste põhjal klassifitseerimine ja seejärel ennustatud klassi põhjal ühendatud segmentide spektraalsete ja kuju omaduste põhjal klassifitseerimine.

Algselt katsetati kraavid ja kraavid taimestikuga eraldi klassidena, aga saadud tulemuste põhjal otsustati töövoogu modifitseerida. Tulemuste parandamiseks katsetati muudetud töövoogu, kus kraavid ja kraavid taimestikuga ühendati vahepeal ühte klassi ja lisati rohkem treeningsegmente, mis olid algselt valesti klassifitseeritud. Allpool on esitatud kahe ja kolme kanali andmekomplektiga objektipõhise pildianalüüsi modifitseeritud töövood, mis on algsetega sarnased ja algsetest töövoogudest erinevad ainult lisatud 8 sammuga ja edaspidi väiksema klasside arvuga.

Objektipõhine pildianalüüs kombineerituna avatuse indeksi ja normaliseeritud maakatte kõrgusmudeliga (edaspidi 2B):

- 1) Rastrite väärtuste normaliseerimine. Positiivse avatuse rastri väärtused varieeruvad vahemikus 1,05 kuni 1,8 radiaani ning nDSM rastri väärtused 0 – 35 m. Normaliseerimiseks kasutati QGIS sisseehitatud ümber skaleerimise algoritmi „*Rescale raster*“, mis normeerib rastri väärtused lineaarselt seadistatud väärtusteni. Peale normaliseerimist mõlema rastri väärtused varieeruvad 0,00 – 1,00. Normaliseerimine on vajalik, et ühtlustada ja paremini kontrollida kõikide rastrite kaalu segmenteerimises.

- 2) Kuna maakatte kõrgusmodeli andmed on suurema varieeruvusega, siis madalaid puid on normaliseeritud rastrist raske segmenteerimisel välja saada. Sellisel juhul korrutati normaliseeritud nDSM 2, 3, 5 ja 10ga, et kontrollitult nDSM-i kaalu segmenteerimises suurendada ning segmenteerimisel hakkasid rohkem ilmuma madalama taimestikuga segmendid. Potentsiaalsete kraavide segmentide arv nDSM võimendusega kahaneb - kümnekordse võimendatud nDSM rastri segmenteerimisel avatuse indeksit peaaegu ei arvestata. Lõplikus variandis otsustati avatuse indeksi ja maakatte kõrgusmodeli suhteks (kaaludeks) jätta 1:2. Andmekihid pandi kokku kahe kanali rastriks ruumilise lahutusega 1 m.
- 3) Segmenteerimine ja selle parameetrite valik on väga oluline ja ajamahukas protsess. Selles lähenemises on segmenteerimist läbi viidud kasutades tervet andmekomplekti koos. Segmenteerimiseks kasutati Orfeo Toolbox QGISi moodulina tööriista *Segmentation*. Seadistatavate parameetrite loetelu on allpool ja lõplikud valitud parameetrid on välja toodud Tabelis 2.
- Segmenteerimise algoritm – proovitud ainult *meanshift segmentation*. Punktid b-f on seadistused, mis kehtivad ainult *meanshift* valikul.
 - Ruumiline raadius – katsetatud väärtuste vahemik 1-15, kus väärtus 15 mõjutab rohkem lineaarseid objekte segmenteerima ja väiksemad väärtused annavad kompaktsemad segmentide kujud.
 - Ulatuse raadius – katsetatud väärtuste vahemik 0,01-1,00 ja sõltuvalt kihtide spektraalsest ulatusest mõju segmenteerimisele oli erinev.
 - Koondumise lävend – kombinatsioonis ulatuse raadiusega ning sõltuvalt samuti kihtide spektraalsest ulatusest mõju segmenteerimisele on erinev. Katsetatud väärtuste vahemik 0,1-1,5.
 - Maksimaalne iteratsioonide arv – parameeter on vaikimisi 100 ning selle muutmist ei katsetatud.
 - Minimaalne segmendi suurus – suurus pikslites. Kui segmendi suurus ületab märgitud väärtust, siis segment ühendatakse naaber segmendiga, mis on spektraalselt kõige lähedasem. Katsetatud väärtuste vahemik 10 – 100.
 - Mask – algoritm võimaldab arvutusmahu vähendamiseks kasutada maski. Antud töös kasutati põllumassiivide maski (vt. kaardialgebra lähenemine), mis märgatavalt vähendab arvutamise aega.
 - 8 naabri ühenduvus – linnuke on sees, vaikimisi on 4 naabri ühenduvus.
 - Ühenda polügonid (*Stitch polygons*) – linnuke on sees.

Tabel 2 Segmenteerimise parameetrid. * Kolme kanali rastri puhul kasutati muud ulatuse raadiuse parameetri

Parameeter	Saaremaa	Kesk-Eesti	Lõuna-Eesti
Segmenteerimise algoritm	meanshift	meanshift	meanshift
Ruumiline raadius (<i>Spatial radius</i>)	15	15	15
Ulatus (<i>Range radius</i>)	0,03	0,03	0,01 (0,02*)
Koondumise lävend (<i>Mode convergence threshold</i>)	0,1	0,1	0,1
Maksimaalne iteratsioonide arv (<i>Maximum iterations number</i>)	100	100	100
Minimaalne regiooni suurus (<i>Minimum region size</i>)	40	40	40
Mask (<i>Mask Image</i>)	Põllumassiivide mask	Põllumassiivide mask	Põllumassiivide mask
8-naabri reegel (<i>8-neighbour connectivity</i>)	Jah	Jah	Jah
Polügonide ühendamine (<i>Stitch polygons</i>)	Jah	Jah	Jah

- 4) Segmentide statistika arvutamine – OTB algoritmiga *ZonalStatistics* arvutati iga segmendi statistilised näitajad: pikslite arv, spektraalsed keskmised ja standardhälve.
- 5) Esimese klassifitseerimise taseme klassid on taimestik, kraav, kraav taimestikuga ja muu. Nendele vastavad treeningpunktid saadi käsitsi ortofoto ja kõrgusmodelite interpreteerimisel. Seejärel ühendati treeningpunktide ja segmentide statistika tabelid ruumiliselt.
- 6) Esimeses klassifitseerimise etapis katsetati erinevate mudelite treenimisega: tugivektormasin (*support vector machine*), tehismärgivõrk (*neural network*) 5 ja 10 neuronide arvuga igas peidetud kihis, juhuslik mets (*random forest*) ning k-lähima naabri meetod.
- 7) Järgmise sammuna eemaldati kõik taimestiku ribad, mis asuvad põllumassiivide piiridel metsamassiivides:
 - a. ETAK-i taimestiku kihist eemaldati kõik objektid, mis on väiksemad kui 0,5 ha, sest selline on maksimaalne põllusaare pindala ning taimestiku kihis on osad põllusaartest olemas. Seetõttu ei olnud vaja tulemustest eemaldada.
 - b. ETAK-i puittaimestiku kihile loodi 10-meetrine puhver.
 - c. Ruumilise päringuga valiti kõik taimestikuks klassifitseeritud segmendid, mis ristuvad puhverdatud metsamassiivi kihiga ja eemaldati need esimese klassifitseerimise tulemustest.
- 8) Klassid kraav ja kraav taimestikuga ühendati omavahel, et edasisel masinõppe treenimisel kraavidel oleks iseloomulik piklik kuju ja avatuse indeksi tõttu põllusaarte servadesse tekkinud kraavideks klassifitseeritud segmendid oleksid teises etapis klassifitseeritud põllusaartena. Selle jaoks lisati ka rohkem treeningpunkte probleemsetesse kohtadesse. See samm andis märgatava tulemuste täpsuse kasvu.

- 9) Saadud segmendid, mis kuuluvad samadesse klassidesse ja asuvad kõrvuti sulatati kokku algoritmiga *dissolve*, mis jagab kõik segmendid 3 multipolügoni. Seejärel jagati üksikuteks polügonideks.
- 10) Arvutati uuesti statistika OTB algoritmiga *ZonalStatistics* ja lisaks arvutati kuju indeksid SAGA algoritmiga *Polygon shape indices*.
- 11) Uuesti loodi treeningpunktide kiht, kus seekord oli 5 klassi: põllusaar, kraav, hekk, puude rida ning muu/põld. Katsetamiste käigus selgus, et heki ja puude rea eristamine ei ole juhuslikust klassifitseerimisest parem, sest ka looduses on need maastikuelemendid väga sarnased. Seega kasutati lõpuks 4 klassi: lineaarne maastikuelement taimestikust, põllusaar, kraav ja muu. Treeningalade loomise töömahu vähendamiseks kasutati PRIA maastikuelementide kihist saadud tsentroidide, korregeeriti neid ning lisati puuduolevaid punktid.
- 12) Treeningpunktide kiht ühendati ruumiliselt ühendatud segmentidega.
- 13) Mõlema kihi keskmise ja standardhälve ning segmenti maksimaalse pikkuse ja kuju indeksi järgi treeniti klassifikaatorit. Testiti sarnaselt esimesele klassifitseerimisele tugivektormasinat, tehismärgivõrku, juhuslikku metsa ja k-lähima naabri meetodit.
- 14) Tulemustest eemaldati ka hooned ja teised ehitised samamoodi nagu kaardialgebra lähenemisel, aga vektorkujul.

Objektipõhine pildianalüüs kombineerituna avatuse indeksi, normaliseeritud maakatte kõrgusmudeli ja normaliseeritud taimkatte indeksiga (edaspidi 3B):

- 1) Ortofotost tuletati NDVI indeks ja ruumiline lahutus viidi 0,25m pealt 1m peale.
- 2) Avatuse indeksi, nDSM ja NDVI väärtused normaliseeriti vahemikku 0...1 ja andmekihid pandi kokku kolme kanali rastriks.
- 3) Segmenteerimise parameetreid (Tabel 2) katsetati võimendades nDSM kaalu 2 ja 3 kordselt ning lõpuks kasutati kahekordset võimendust.
- 4) Statistika arvutamine (vt. punkt 4 eelmisest lähenemisest)
- 5) Esimese klassifitseerimise taseme klassid olid taimestik, kraav, kraav taimestikuga, hooned ja muu. Erinevalt eelmises lähenemises kasutatud klassidest, hooned lisati sellepärast, et NDVI indeksi väärtuste põhjal on võimalik eristada hoonete katused kõrgest taimestikust. Nendele vastavad treeningpunktid saadi käsitsi ortofoto ja kõrgusmodelite interpreteerimisel. Seejärel ühendati treeningpunktide ja segmentide statistika tabelid ruumiliselt.
- 6) Kahe kõrgusmudeli lähenemine näitas, et parimaid tulemusi saab kasutades juhusliku metsa või tehismärgivõrku ja seetõttu tugivektormasinat enam ei testitud. Seekord katsetati juhuslikku metsa ning tehismärgivõrku viie ja kümne neuronide arvuga igas peidetud kihis. Kolm tulemust olid visuaalselt võrreldes omavahel väga sarnased, aga natuke kiirem oli mudeli treenimine juhusliku metsa puhul, mistõttu valiti lõplikuks meetodiks juhuslik mets.
- 7) Metsa ribadest lahti saamine (vt. punkt 7 eelmisest lähenemisest)
- 8) Kraav ja kraav taimestikuga klasside ühendamine (vt. punkt 8 eelmisest lähenemisest)
- 9) Sama klassi segmendid ühendati omavahel, arvutati uuesti spektraalne statistika ja kuju indeksid.

- 10) Järgmise sammu treeningandmetes oli 5 klassi: lineaarne taimestikust maastikuelement, põllusaar, kraav, hoone ja muu. Punktid treeningalade valimiseks pandi käsitsi ortofotode ja kõrgusmodelite põhjal.
- 11) Teise etapi klassifikaatori treenimine ei erine eelmise lähenemise omast välja arvatud NDVI kihi lisamine.

3.2.3 Tulemuste valideerimine

Tulemuste valideerimiseks kasutati PRIA maastikuelementide kihti, kuhu olid käsitsi lisatud need maastikuelemendid, mis PRIA andmebaasist olid puudu. Näiteks selline põllusaar või kraav, mis asub kahe põllumassiivi piiril ja puudub andmebaasist, kuna asub erinevatele omanikele kuuluvate põllumassiivide piiril. Metsa ja põllu piiril asuvad kraavid klassifitseeritakse hetkel PRIA-s maastikuelemendiks juhul, kui kraavi servad on tuvastatavad ortofoto või kohapealse kontrolli põhjal. Käsitsi lisati kõik kraavid, kaasa arvatud metsa ja põllu piiril asuvad kraavid taimestiku all, sest antud andmestikuga oli võimalik neid tuvastada. Samas PRIA poolt määratletud tingimust, et valgala suurus kraavil peab olema 10 km² antud töös ei olnud võimalik arvestada. Põllusaartest lisati kõik potentsiaalsed maastikuelemendid välja arvatud võsastunud põldudel üksikud põõsad või võsa massiivid. Üldjuhul lisati valideerimisandmestikku ainult ilmselged maastikuelemendid.

Meetodite 2B ja 3B tulemused valideerimiseks koondati nelja klassi:

- Lineaarsed taimestikuga maastikuelemendid – nendele vastavad PRIA andmebaasist hekid, puude read ja metsasiilud.
- Põllusaared – vastavalt PRIA põllusaared
- Kraavid – vastavalt PRIA kraavid
- Muu – kõik muud alad

Pikslipõhise pildianalüüsi valideerimiseks kasutati kolme klassi:

- Taimestikuga maastikuelemendid – vastavalt PRIA andmebaasist hekid, puude read, metsasiilud ja põllusaared
- Kraavid – vastavalt PRIA kraavid
- Muu – kõik muud alad

Tulemuste hindamiseks arvutati iga mudeli jaoks Lõuna-Eestis, Kesk-Eestis ja Saaremaal kolm veamaatriksit:

- Maastikuelementide klasside vaheline veamaatriks, kus hinnati maastikuelementide erinevate klasside klassifitseerimise täpsust. Selle veamaatriksi kogutäpsus näitab, kui õigesti mudel suudab klassifitseerida segmendi või piksli õigesti maastikuelemendi klassi.
- Veamaatriks, kus hinnati maastikuelementide indikatiivset täpsust. Selles matriksis oli 2 klassi: maastikuelement ja muu. Selle veamaatriksi kogutäpsus näitab kui suure pindala maastikuelementidest valideerimisandmestikust mudel klassifitseeris maastikuelemendina.

4 Tulemused ja arutelu

4.1 Kaardialgebra

Vaatamata meetodi lihtsusele, oli maastikuelementide vaheline kogutäpsus 86,78%. Taimestiku tootja- ja kasutajatäpsused on madalamad (Tabel 3). Suur hulk taimestiku pikslid oleks võimalik vektorkujul tulemustest välja puhastada sarnaselt objektipõhise pildianalüüsile, mis tõstaks tulemuste kasutaja- ja tootjatäpsusi.

Tabel 3 Kaardialgebra tulemuste maastikuelementide vahelised keskmised tootja- ja kasutajatäpsused üle Eestit

Tootjatäpsus		Kasutajatäpsus	
Kraav	93,47%	Kraav	90,23%
Taimestik	63,88%	Taimestik	68,20%

Kõige kehvemad maastikuelementide vahelised täpsused Eestis esinesid Saaremaal, mida põhjustasid peamiselt põllusaarte servades esinenud suured vallid, mis põhjustasid avatuse indeksi põhjal valli kraaviks klassifitseerimise. Siin tulevad esile pikslipõhiste meetodite nõrkused kõrge resolutsiooniga andmete klassifitseerimisel, kus pikslid ei esinda terviku objekti, vaid ainult selle väikest osa (Riggan ja Weih, 2009; Whiteside et al., 2011). Kõige kõrgemad kraavide tuvastamise täpsused olid Lõuna-Eestis, kus oli kõige rohkem madalaid kraave, ja kõige vähem järske kõrguste vahesid, mis on valepositiivsete kraavide pikslite allikad. Kõikide veamaatriksitega saab tutvuda lisades 1 ja 2.

Kaardiruutude vahel taimestiku tuvastamise täpsus langeb vastavalt põllumassiivide servade pikkuse suurenemisega. See on tingitud 15 meetrisest põllumassiivide maski puhvrist, mille eesmärk oli tuvastada kõike põldude piiril asuvaid maastikuelemente kuid sinna sattus kõige suurem osa valepositiivseid ennustusi. Taimestiku tuvastamise täpsused olid kõige madalamad Saaremaal, mis on tingitud suurest põldudevaheliste metsaribade arvust, mida on maastikuelemendiks klassifitseerimine on vaieldav ja üldiselt suurest põllumassiivide servade pikkusest.


Erinevalt objektipõhisest analüüsist, ei sõltu kaardialgebra tulemused treeningandmetest, vaid pigem eksperthinnangust, millised kombinatsioonid kaardialgebrasse lisada. Arvutusressurssi poolest on pikslipõhine lähenemine kordades kiirem. Kaardialgebra tulemusena tuvastati kolm klassi: taimestikust maastikuelemendid ning taimestikuta ja taimestikuga kraavid.

Tulemus oli rastri kujul ja ei olnud puhastatud üleliigsetest taimestiku pikslitest aladel, mis on ETAK-i metsamassiivide osad. Seda ei tehtud sellepärast, et kiire kaardialgebra lähenemine sobib rohkem kasutamiseks indikaatorina maastikuelementide olemasolu tuvastamiseks. Uute andmetega korduva algoritmi käivitamise järel saab leida kohti, kus on tekkinud uued maastikuelemendid või on maastikuelemendid hävinud. Juhul, kui ETAK-i puittaimestiku kiht oleks vahepeal muudetud, kaardiruudus tekiks muudetud aladele indikatiivset pikslid, mis ei esinda reaalselt toimunud muudatusi, vaid ainult muudatusi ETAK-i kihis.

4.2 Objektipõhine pildianalüüs

Metoodikas katsetatud segmenteerimise parameetritest olid valitud need, mis kõige paremini piiritlesid potentsiaalseid maastikuelemente (Tabel 2). Segmenteerimise parameetrite valimiseks kulus kõige rohkem aega objektipõhise pildianalüüsi meetodi väljatöötamisel. Sellisest probleemist kirjutavad paljud objektipõhise pildianalüüsiga seotud metoodiliste tööde autorid (Jeong et al., 2019; Voormansik, 2016). Johnson & Lei (2020) on oma ülevaate artiklis koondanud objektipõhise pildianalüüsi metoodikate probleemid ja mitmed neist keskendusid segmenteerimise parameetrite valikule. Põhirõhk optimaalsete segmenteerimise parameetrite valikul tehakse lokaalsetele parameetrite valikutele, mis tabab rohkem lokaalseid maastiku iseärasusi. Ka käesolevas töös Lõuna-Eestis kasutati pisut erinevad segmenteerimise parameetrid, sest Saaremaal ja Kesk-Eestis kasutatud parameetritega osad kraavidest Lõuna-Eestis ei oleks segmenteerimises piiritletud.

Kahe ja kolme kanali rastrite segmenteerimine andis erinevad tulemused. Kolme kanali rastril puhul aitas lisatud NDVI indeks paremini segmenteerida põllusaared, kus ei kasva suurt võsa või puid (Joonis 11). Selliste põllusaarte klassifitseerimine masinõppega ei parandanud oluliselt kahe kanali rastri tulemusi. Modifitseeritud töövoog aga parandas kõige rohkem põllusaarte tuvastamise täpsust (Joonis 11). NDVI indeksi lisamine andmekomplekti aitas eemaldada hoonetest puhastamise sammu ja paremini piiritleda põllusaared, millel ei kasva kõrget taimestikku. Samas kolme kanali rastri tulemused ei parandanud kogutäpsusi ega tootja- ja kasutajatäpsusi võrreldes kahe kanali rastri tulemustega (Tabel 4). Voormansik (2016) leidis oma töös samuti, et NDVI lisamine ei tõstnud oluliselt klassifitseerimise täpsust. Põhjusteks on eeldatavasti esinduslike õpetusalade nappus ühe kaardiruudu piires ja põllusaartele iseloomuliku NDVI väärtuste vahemiku puudumine (esineb nii täielikult taimestikuga kaetud põllusaari kõrgete NDVI väärtustega kui ka kivide hunniku ümber kasvavatest üksikutest puudest koosnevaid põllusaari madalate NDVI väärtustega (nt. Joonis 11)). Selle tõttu on osad 2B meetodiga õigesti klassiks „muu“ klassifitseeritud segmente on 3B meetodiga klassifitseeritud maastikuelementideks, mis alandas 3B tulemuste täpsusi vaatamata 3B meetodiga paremini saadud maastikuelementide piiridele.



Joonis 11 a) Kahe kanali; b, c) kolme kanali rastri segmenteerimise tulemused (valgega märgitud segmentide piirjooned); d) kahe kanali rastri klassifitseerimise tulemus; e) kolme kanali rastri klassifitseerimise tulemus; f) modifitseeritud kolme kanali rastri klassifitseerimise tulemus

Objektipõhise pildianalüüsi maastikuelementide vahelised keskmised kogutäpsused on:

- 2B: 82,53% ja 86,92%*
- 3B: 80,99% ja 86,52%*, (* modifitseeritud mudeli tulemus)

Kraavide ja taimestikuga kraavide ühendamise kahe klassifitseerimise etapi vahesammuna andis üldiselt paremad tulemused, kus kogutäpsused kasvasid 4,39% ja 5,53% võrra kahe ja kolme kanali rastri klassifitseerimisel. Modifitseeritud töövoog tõstis oluliselt põllusaarte tootjatäpsusi (40,46% ja 31,09% võrra) kuid alandas lineaarse taimestiku ja kraavide tootjatäpsusi mõne protsendi võrra. Modifitseeritud töövooga kasvasid ka kõikide maastikuelementide tüüpide kasutajatäpsused 2,3% - 10,37% võrra (Tabel 4). Tamm et al. (2014) saavutas metsa ja põõsastiku klassile kõrgemad klassifitseerimistäpsused (kasutaja- ja tootjatäpsused vastavalt 97% ja 96%) kui käesolevas töös põllusaarte klassifitseerimistäpsus. Põllusaarte madalam täpsus on tingitud enamasti käesolevas töös põllumassiivide maski rakendamisega ajakulu vähendamiseks, mis tekitas põllumassiivide servades palju valesti klassifitseeritud segmente. Metsa ja põõsastiku tuvastamisel Tamm et al. (2014) töös sellised vigaderikkad servaalad puudusid.

Tulemustes on märgata madalaimat kasutajatäpsust lineaarsete taimestikust maastikuelementide puhul. See on tingitud sellest, et tulemused sõltuvad valepositiivsetest ennustustest puhastamisest, mis omakorda sõltub ETAK vektorandmete kvaliteedist (Joonis 13).

Tabel 4 Objektipõhise pildianalüüsi tulemuste maastikuelementide vahelised keskmised tootja- ja kasutajatäpsused üle Eesti. * modifitseeritud mudeliga

Tootjatäpsus					Kasutajatäpsus				
	2B (%)	2B* (%)	3B (%)	3B* (%)		2B (%)	2B* (%)	3B (%)	3B* (%)
Kraav	88,65	85,63	85,81	85,26		93,17	99,12	93,17	99,23
Lineaarne taimestik	84,56	77,87	78,81	78,20		31,44	39,11	29,32	38,20
Põllusaar	56,72	97,18	62,11	93,20		71,60	73,90	61,12	71,49

Töös katsetati erinevaid masinõppe meetodeid klassifitseerimise protsessis. Parima tulemuse andis esimestel klassifitseerimise etappidel juhuslik mets. Seda otsustati kasutada ka ülejäänute klassifitseerimise käigus. Kucharczyk et al. (2020) ja Zhao et al. (2017) toovad oma töödes välja, et tehishärvivõrkude treenimiseks kulub palju aega, mis tuli ka esile käesolevas töös. Shabab et al. (2019) mainis tehishärvivõrkude pisut edukamaid tulemusi võrreldes juhusliku metsaga, kuid käesolevas töös esimese klassifitseerimise etapi käigus visuaalsel hindamisel olulist vahet ei leitud.

Teised katsetatud masinõppe meetodid olid ajaliselt juhusliku metsaga sarnase ajakuluga, kuid tulemuste poolest toimusid halvemini. K-lähima naabri meetodi ja tugivektormasina arvutusmahud suurenevad kiiresti andmemahu suurenemisega. Kuna käesolevas töös aga andmemahu oli piisavalt väike, siis mudeli treenimine toimus suhteliselt kiiresti. Oma rolli käesolevas töös mängis pigem nende meetodite parameetrite valiku keerukus (Cervantes et al., 2020; IBM 2022), kuna töös kasutati OTB algoritmide vaikimisi seaded.

4.3 Ajakulu

Antud töös katsetati meetodikaid ainult kolmel 5×5 km treening- ja valideerimisalal. Terve Eesti arvutamiseks arvutamisesurssi maht kasvab arvetatavalt ja ajakulu mängib rolli. Antud töös viidi arvutused läbi viidud arvutiga järgmiste spetsifikatsioonidega:

- Protsessor - AMD Ryzen 5 3500U koos Radeon Vega Mobile Gfx, 2,10 GHz
- Muutmälu – 16 GB (millest 13,9 GB kasutatavad)
- Süsteem – Windows 10 Pro

Kaardialgebra lähenemine on kõige kiirem ja lihtsam variant katsetatud meetodikatest. Ühe kaardiruudu 1 m ruumilise lahtusega maski valmistamine võttis keskmiselt 2 sekundit. Kaardialgebra tehed ei ületanud paari sekundit. Vektorkihtidega tehed on antud meetodikas lihtsad ja võtavad aega samuti kuni 3 sekundit. Kui protsess oleks automatiseeritud, siis kogu kaardialgebra meetodika töövoog ajakulu ei ületaks 1 minutit (Tabel 5) ühele kaardiruudule. Kogu Eesti ajakulu 2084 kaardiruutudega oleks vastavalt ligikaudselt 34 tundi.

Arvestamata masinõppe mudelite ettevalmistamise aega, võttis objektipõhise pildianalüüsi lähenemine üle kümne korda rohkem aega kui kaardialgebra lähenemine. Ainuüksi segmenteerimiseks kulus 350-460 sekundit, mis on objektipõhise pildianalüüsi kõige mahukam protsess. Terve protsess automatiseeritult on läbiviidav ühel kaardilehel umbkaudselt kümne

minuti jooksul (Tabel 6). Kogu Eesti ajakulu arvutamine objektipõhise pildianalüüsi puhul on keerukam. Käesolevas töös kasutatud meetodikas ajakulukaim protsess oli segmenteerimine, mis sõltus põllumassiivide maski pindalast – mida vähem põllumassiive kaardiruudus, seda kiirem on segmenteerimine. PRIA põllumassiivide pindala osakaal Eesti pindala suhtes on umbkaudselt 21,5%. Põllumassiivide maski kasutamine kaardiruudus, kus põllumassiivide osakaal on 57% vähendas segmenteerimise aega võrreldes terve kaardiruudu segmenteerimisega 1,4 korda. Kui hinnanguliselt arvestada kahekordselt väiksema keskmise segmenteerimise ajaga võrreldes töös kasutatud kaardiruutude segmenteerimise ajaga, siis kogu Eesti arvutamise ajakulu oleks kahe kanali rastri puhul umbes 8 ööpäeva, kolme kanali rastri puhul 10,5 ööpäeva.

Tabel 5 Kaardialgebra protseduuride ajakulu

Protseduur	Aeg (sek)
Avatuse indeksi arvutamine	30
Põllumassiivide puhvri loomine	2
Põllumassiivide maski konverteerimine rastroks	1
Põllumassiivide rastri ümber klassifitseerimine	2
Maakatte maski loomine	2
Ehitiste kihtide ühendamine	1
Ehitiste maski konverteerimine rastroks	1
Ehitiste rastri ümber klassifitseerimine	2
Kraavide maski loomine	2
Piiretele puhvri loomine	2
Piirete maski konverteerimine rastroks	1
Puhastatud kraavide maski loomine	2
Esialgse potentsiaalsete maastikuelementide kihi loomine rastri kalkulaatoris	3
„Sõelaga“ puhastamine	2
Kokku	53

Tabel 6 Objektipõhise pildianalüüsi ajakulu

Avatuse indeks + nDSM		Avatuse indeks + nDSM + NDVI	
Protseduur	Aeg (sek)	Protseduur	Aeg (sek)
Avatuse indeksi arvutamine	30	Avatuse indeksi arvutamine	30
Ehitiste kihtide ühendamine	1	Ortofoto ruumilise lahutuse konverteerimine	1
-		NDVI arvutamine	2
Rastrite normaliseerimine	2	Rastrite normaliseerimine	3
Segmenteerimine	350	Segmenteerimine	460
Spektraalse statistika arvutamine	15	Spektraalse statistika arvutamine	25
Esimene klassifitseerimine	3	Esimene klassifitseerimine	3
Metsamassiivide kihist potentsiaalsete põllusaarte eemaldamine	2	Metsamassiivide kihist potentsiaalsete põllusaarte eemaldamine	2
Metsamassiivide puhvri loomine	1	Metsamassiivide puhvri loomine	1

Ruumiline päring	10	Ruumiline päring	10
Kraavide ühendamine	2	Kraavide ühendamine	2
Sama klassi segmentide ühendamine	55	Sama klassi segmentide ühendamine	80
Multipolügoonist üksikute polügoonide loomine	1	Multipolügoonist üksikute polügoonide loomine	1
Spektraalse statistika arvutamine	12	Spektraalse statistika arvutamine	12
Kuju omaduste arvutamine	15	Kuju omaduste arvutamine	23
Teine klassifitseerimine	3	Teine klassifitseerimine	3
Tulemuste puhastamine ehitistest	2	-	
Kokku	504	Kokku	658

4.4 Tulemustest kokkuvõte

Objektipõhiste meetodite puhastamise efekti on näha indikatiivses veamaatriksis (Tabel 7) maastikuelementide keskmise kasutaja- ja kogutäpsuse lahtrites, kus väärtused on kaardialgebra puhastamata tulemustel on võrreldes objektipõhiste mudelitega madalamad. Tootjatäpsused on aga kõrgemad kaardialgebra meetodi puhul. Madalad maastikuelementide kasutajatäpsused (alla 27%) on tingitud suure valepositiivsete ennustuste arvust ja üldiselt väikese maastikuelementide pindalast võrreldes muu alaga.

Tabel 7 Indikatiivsete veamaatriksite keskmised väärtused üle Eesti. * modifitseeritud mudeliga


	Kaardialgebra	2B	2B*	3B	3B*
Kogutäpsus keskmine	95,79%	97,51%	97,53%	97,61%	97,45%
Keskmine kasutaja täpsus	58,49%	62,71%	62,89%	62,99%	62,54%
Keskmine tootja täpsus	90,28%	86,79%	87,09%	86,30%	87,19%
Maastikuelementide keskmine kasutaja täpsus	17,13%	25,67%	26,02%	26,24%	25,31%
Maastikuelementide keskmine tootja täpsus	84,67%	75,84%	76,44%	74,76%	76,73%

Üldiselt võib tõdeda, et kogutäpsused nii kaardialgebra kui ka objektipõhiste meetodite puhul on kõrged. Kaardialgebra ja objektipõhine 2B meetod ei suuda väga efektiivselt tuvastada taimestikuga ja taimestikuta põllusaari, millel puudub suur maapinna kõrguste vahe. 3B lähenemine on aga põllusaarte tuvastamisel kõige edukam aga ajaliselt kõige nõudlikum meetod.

Kraavide tuvastamine õnnestus kõige paremini kaardialgebra meetodi abil, kuid probleemiks on, et tulemustesse jääb palju valepositiivseid piksleid. Objektipõhiste meetodite puhul mõned kraavide osad jäävad tuvastamata ja taimestiku all olevad kraavide servad ei lange alati reaalsete kraavide servadega kokku segmenteerimisest tulenevatel põhjustel. Paljud väikesed kraavid, mis asuvad puude all on üldse objektipõhise pildianalüüsi puhul klassifitseeritud taimestikuks, sest masinõpe jaoks avatuse indeksi väärtused ei ole ainuke kriteerium erinevalt kaardialgebrast, kus iga andmekiht oli eraldi klassifitseeritud lävendi põhjal.

Objektipõhise pildianalüüsi tulemused on puhtamad, objektid on üldistatumad ja omavad selgeid piire (Joonis 12a), mis on kooskõlas Riggan ja Weih (2009) ja Whiteside et al. (2011) uuringutes

välja toodud meetodite nõrkade ja tugevate külgedega. Kaardialgebra väljundis on näha pikslipõhisele klassifitseerimisele iseloomuliku „soola-pipra“ efekti (Joonis 12b). Joonisel 12 on näha ka segmenteerimise kvaliteedist ja masinõpe üldistamisest tingitud kraavi katkestust, mida kaardialgebra tulemusel näha ei ole.




Joonis 12 Kaardialgebra (a) ja objektipõhise pildianalüüsi (b) tulemuste näidis

Kaardialgebra kraavide tootjatäpsused on umbes 5% võrra kõrgemad võrreldes objektipõhise pildianalüüsi tulemustega, kuid samas on kraavide kasutajatäpsused kõrgemad objektipõhise pildianalüüsi tulemustes. See on tingitud kaardialgebra valepositiivsete kraavide pikslite puhastamise raskusest.

Nii kaardialgebra kui ka objektipõhiste meetodite tulemuste puhastamine oli antud töö kitsaskohaks. Rakendatud objektipõhises metoodikas eemaldab ETAK-i metsamassiivide mask suure osa taimestikuks klassifitseeritud segmente, mis asuvad metsa ja põllu piiril, kuid selle meetme efektiivsus sõltub ETAK puittaimestiku kihi kvaliteedist ja ajakohasusest (Joonis 13). Teine suur valepositiivsete alade allikas on teeäärsed kraavid ja teetammide kõrvale tekkivad

kraavide pikslid ja segmendid, mis jäävad põllumassiivide maski sisse, aga maastikuelementideks on nende klassifitseerimine kahtlane.




Joonis 13 Tulemuste ETAK puittaimestiku kihi abil puhastamise sõltuvus ETAK kihi kvaliteedist

Kaugseire tulemuste täpsuse edukuse kriteeriumiks loetakse tihti vähemalt 85% tootjatäpsust, mida Giles (2008) peab eksitavaks, rõhutades vajadusele edukuse kriteeriumi defineerimisel lähtuda konkreetse kaugseire rakenduse kontekstist. Käesolevas töös suudeti see kriteerium täita kraavide tuvastamisel mõlema meetodiga ning põllusaarte tuvastamisel modifitseeritud objektipõhise pildianalüüsi mudeliga.

4.5 Võimalused tulemuste parandamiseks

Osade maastikuelementide vale tuvastamine antud töös oli tingitud andmete vanuse erinevusest maapinna kõrgusmudeli ning maakatte kõrgusmudeli ja ortofotode vahel (Tabel 1). Näitena võib välja tuua Saaremaal 2017. ja 2019. aasta vahemikus toimunud kraavi asukoha muutusest (Joonis 14). Maa-ametis maapinna (DEM) ja maakatte (DSM ja nDSM) kõrgusmudelid on arvutatud intervalliga 2 aastat ja seetõttu esineb olukordi, kus DEM on vanem kui DSM ja vastupidi. Põhjuseks on lennuaeg, mis DEM-i valmistamiseks valitakse kevadel, kui puud ei ole lehes ja maapind on kergemini LiDAR-i impulssidele kättesaadav. DSM valmistamiseks lennatakse aga suviti, kui puud on lehes ja maakatte kõrgeimad punktid on kergemini kättesaadavad (Maa-amet,

2022d). Andmete vanuse ühtlustamiseks on võimalik iseseisvalt kas maapinna või maakatte kõrgusmodelid LiDAR toorpunktpilvest luua.



Joonis 14 Näide ortofoto (ja nDSM) erinevusest maapinna kõrgusmudelist (DEM). Vasakpoolsel pildil on 2019. aasta ortofoto. Parempoolsel pildil 2017. aasta DEM-ist tuletatud avatuse indeks tumedamate kraavi pikslitega. Valgega on näidatud uus kraavi asukoht, nähtav 2019. aasta ortofotol.

Käesoleva töö valideerimisandmestikku valmistati ainult ilmselgetest maastikuelementidest, kuhu ei lisatud kõiki vaieldavaid maastikuelemente. Näiteks ei lisatud selliseid objekte, mis ei vastanud PRIA maastikuelementide parameetritele, kuid loogiliselt maastiku seisukohalt oleks võimalik ka neid maastikuelementide hulka lisada. Suur osa selliseid maastikuelemente on klassifitseerimisel tuvastatud, kuid valideerimisandmestikus puudusid. Näiteks valepositiivsed segmendid tekkisid enamasti õuealade ümber, kus algoritm tuvastas lineaarseid maastikuelemente aga valideerimisandmestiku need lisatud ei olnud, sest PRIA neid üldjuhul maastikuelemendina ei käsitle. Valideerimisandmestiku laiendamisel saaks tulemuste täpsust tugevalt tõsta, aga töö sisu see ei muudaks.

Kokkupandud andmekomplektide segmenteerimise vastuvõetavad tulemused vähendasid eraldi kihtide segmenteerimist ja nende tulemuste kombineerimise vajadust nagu oli kirjeldatud peatükis „Objektipõhine pildianalüüs kõrge resolutsiooniga andmetega“. Siiski segmenteerimise osas oleks võimalik tulemust parandada, kui segmenteerida eraldi avatuse indeksi ja nDSM rastrid ja seejärel ühendada segmendid omavahel, et saada kindlamad potentsiaalsete maastikuelementide piirid. Sarnased meetmed toob välja Sébastien et al. (2019) omas uuringus. Selle meetmega teoreetiliselt saaks objektipõhise pildianalüüsi kraavide tootjatäpsust tõsta kaardialgebra tulemusteni, sest see meede parandaks taimestiku all olevate kraavide piire ja selle kaudu ka segmentide spektraalsed omadused oleksid esinduslikumad masinõpe jaoks. Käesolevas töös jäid väikesed kraavid puude all tihti tuvastamata.

Masinõpe meetodite (juhuslik mets ja tehishärvivõrk) osas olid tulemused omavahel väga sarnased ja olulist erinevust ei tuvastatud. Osa uuringutest näitavad aga tehishärvivõrkude edukamaid tulemusi võrreldes juhusliku metsa või tugivektormasina klassifitseerimise algoritmidega (Raczko & Zagajewski, 2017; Shabab et al., 2019). Osa uurimusi on aga leidnud, et tugivektormasin edestab kaugseire rakendustes juhusliku metsa ja tehishärvivõrkude tulemusi Zagajewski et al. (2021).

Sheykhmousa et al. (2020) leidis, et multispektraalsete andmete klassifitseerimisel töötab paremini tugivektormasin, kuid kombineeritud andmete (*fused datasets*) klassifitseerimisel aga juhuslik mets. Käesoleva töö põhjal võib väita, et juhuslik mets saavutab häid tulemusi ja pigem oleks võimalik masinõppe tulemust ainult parandada parema ja esinduslikuma treeningandmestikuga.

Uurimisala kaardiruutude valikul lähtuti antud töös põhiliselt kahest kriteeriumist: põllumassiivide osakaalust ja PRIA maastikuelementide andmebaasis olevate maastikuelementide arvust. Sellest tulenevalt on aga arvestamata jäänud mõned probleemsed nähtused antud mudelite jaoks. Näiteks on kaardiruutused, kus on palju õuealasid keset põldu ja kaardiruutused väga mitmekesise reljeefiga Otepää või Haanja kõrgustikel. Käesoleva töö maht ei võimaldanud kõiki Eesti maastikutüüpe piisavalt esinduslikult katta. Seega ei ole teada, kuidas käituksid väljatöötatud meetodid sellistes maastikes. Juhul kui soovida neid meetodeid üle Eesti rakendada, siis peaks veel testimata/treenima meetodeid rohkem eri tüüpi maastikel. Masinõppe puhul on eriti oluline tagada treeningalade esinduslikkus, mis aitaks parandada maastikuelementide tuvastamise täpsust.

Objektipõhise pildianalüüsi modifitseeritud versioonide tulemustes on kõrged klassidevahelised täpsused. See võimaldab täpsusi veel parandada rakendades naabersuhete põhjal klasside loogilisi reegleid. Näiteks põllusaared ei saa ristuda kraavidega või lineaarse taimestikuga. Algsete meetoditega oli see ebaefektiivne – näiteks Saaremaal katsetatud reegel „kraav ei saa ristuda põllusaarega“ eemaldaks suurt osa reaalseid kraave, sest üksikud puud kraavide ümber olid klassifitseeritud põllusaarteks. Modifitseeritud meetoditega on selline probleem kordades väiksem ja reeglite kasutamine saaks üksikute segmentide vale klassi õigeks muuta.

Objektipõhise pildianalüüsi meetoditest jäi rakendamata üks lihtsaim tulemuste puhastamise võte – objekti pindala järgi väikestest artefaktidest puhastamine. Kui lähtuda PRIA maastikuelementide definitsioonist, siis saab väikseim element olla 0,01 ha suurune. Seega võiks väiksemad üksused eemaldada. See aga ei mõjutaks oluliselt tulemuste täpsust nende üksuste väikese pindala tõttu. Antud töös ei eemaldatud neid, sest osaliselt oleks sellisel juhul eemaldatud ka üksikust puust põllusaared, mida sooviti potentsiaalse elemendina säilitada.

Kokkuvõttes võib tõdeda, et käesolevas töös väljatöötatud meetodid näitasid häid tulemusi. Omavaheline väga täpne meetodite võrdlemine oli raskendatud erineva klasside arvu tõttu. Sarnaselt varasematele töödele tulid ka käesolevas töös esile pikslipõhise ja objektipõhise pildianalüüsi tugevad ja nõrgad küljed.

Nii kaardialgebra kui ka objektipõhisel meetodil on oma tugevused ja nõrkused ja sõltuvalt eesmärgist on võimalik mõlemaid rakendada. Vähenõudlik kaardialgebra lähenemine on hea meetod, et seirata maastikuelementide säilimist/hävimist, sest see suutis kiiresti ja piisava täpsusega tuvastata maastikuelementide olemasolu, aga klasside eristamises ei olnud see meetod nii edukas. Objektipõhise pildianalüüs sobilik siis, kui on oluline eristada erinevaid klasse ning eeliseks on see, et tulemusena saadakse objektid vektorkujul selgete piiridega.

Kokkuvõte

Töö eesmärgiks oli töötada välja meetodid maastikuelementide tuvastamiseks kasutades Maaameti kaugseire andmeid ja võrrelda neid omavahel ning hinnata nende kasutuskõlblikkust. Eesmärgist tulenevalt kujunesid välja järgmised uurimisküsimused:

- Milline kaugseirel põhinev meetod on kõige kiirem ja milline on kõige täpsem?
- Kas kaugseire abil on võimalik tuvastada erinevaid maastikuelementide klasse?

Kõik uurimisküsimused said vastuse. Kõige kiiremaks meetodiks osutus kaardialgebra. Kõige täpsemateks meetoditeks indikaatiivselt omavahel võrreldes osutusid objektipõhise pildianalüüsi meetodid kahe või kolme rastri kanali andmekomplektiga. Kaugseire abil on võimalik tuvastada erinevaid maastikuelementide klasse: lineaarsed ja mitte-lineaarsed taimestikust maastikuelemendid ning kraavid.

Esimese sammuna otsustati luua lihtsa ja kiire kaardialgebrale tuginev meetod. Maapinna kõrgusmudelitest tuletatud avatuse indeksi ja normaliseeritud maakatte kõrgusmudeli põhjal loodi lävendipõhised maskid. PRIA põllumassiivide ja ETAK-i ehitiste kihtide abil piirati analüüsi põllumassiivide piiridesse ja puhastati valepositiivsete ennustuste piksleid põllumassiivide aladel. Tulemusena saadi kaks maastikuelementide klassi: kraav ja taimestikust maastikuelement.

Kaardialgebra põhise meetodi keskmine kogutäpsus oli 86,78% ning kraavide klassi tootja- ja kasutajatäpsused on vastavalt 93,43% ja 90,27%. Taimestiku tootja- ja kasutajatäpsused on vastavalt 63,88% ja 68,20%. Tulemused on üldiselt head, kuid esineb pikslipõhistele klassifitseerimistele iseloomulike puudusi: soola-pipra efekt ning kuju ja konteksti mitte arvestamine. Ajakulu poolest võtab antud meetod aega alla 1 minutit ühe kaardilehe kohta, mis teeb selle meetodi tervele Eesti pindalale operatiivselt rakendatavaks.

Lisaks kaardialgebra meetodile, katsetati kaks objektipõhise pildianalüüsi meetodit. Esimesel variandi puhul kasutati ainult kõrgusandmed: avatuse indeksit ja nDSM. Teisel juhul kasutati kõrgusandmed ja ortofotost tuletatud NDVI indeksit. Klassifitseerimine toimus kahes etapis. Esimese etapi segmenteeritud ala klassifitseeriti juhusliku metsa abil ainult spektraalsete omaduste põhjal. Seejärel segmendid omavahel ühendati ja spektraalsetele omadustele lisati kuju indeksid ning klassifitseeriti lõplikult juhusliku metsa abil. Tulemusena saadi kolm maastikuelementide klassi: kraav, lineaarne taimestikust maastikuelement ja põllusaar.

Maastikuelementide vahelised täpsused on osaliselt madalamad kui kaardialgebra puhul kuid maastikuelementide klasse on objektipõhise pildianalüüsi puhul ühe võrra rohkem. Kogutäpsused olid meetodi 2B (avatuse indeks + nDSM) puhul 86,92% ja meetodi 3B (avatuse indeks + nDSM + NDVI) puhul 86,52%. Kraavide tootjatäpsused on kaardialgebraga võrreldes mõne protsendi võrra madalamad, aga kasutajatäpsused vastupidi mõne protsendi võrra kõrgemad. Põllusaarte tootjatäpsused on meetodi 2B puhul (97,18%) ja meetodi 3B puhul 93,20% ning kasutajatäpsused 2B: 73,90% ja 3B: 71,49%. Kõige kehvemad tulemused on lineaarse taimestiku puhul, kus kasutajatäpsused ei ületa 40%. Ajakulu poolest võtab 2B meetod automatiseeritult aega umbes 8,5 minutit olemasoleva mudeliga ühe kaardiruudu klassifitseerimiseks. 3B meetod võtab aega umbes 11 minutit, aga tulemuste täpsuse poolest ei ole 2B meetodist parem.

Kokkuvõttes võib öelda, et väljatöötatud meetodid on sobilikud maastikuelementide seireks. Kaardialgebra variant on hea tööriist maastikuelementide olemasolu tuvastamiseks ning objektipõhiste meetodite abil on võimalik luua Eestis potentsiaalsete maastikuelementide kiht, kus on eristatud peamised maastikuelementide klassid. Väljatöötatud meetodeid on võimalik veelgi tulevikus parandada.

Detection of small-scale landscape elements with remote sensing

Nikita Murin

Summary

The European Union created the Common Agricultural Policy (CAP) in 1962, which aims to provide European farmers with a sustainable environment, enhance agricultural productivity and to supply with numerous other goals beneficial for everyone. There are various fields in CAP to achieve these goals - one of them is greening. The presence of landscape features, such as linear vegetation patches, ditches or small forest islands on agricultural fields, is an important part of greening. It has a positive effect on landscape diversity, animals' biodiversity and habitats connectivity (Marja et al., 2013; Oja et al., 2016; Radoux et al., 2016; Zurqani et al., 2020).

Mapping such landscape elements in Estonia is conducted by Agricultural Registers and Information Board. Landscape features are added into the database manually in line with the farmers' applications. Such system does not provide full picture of landscape elements' presence on agricultural lands in real life due to various complexities in such way of mapping (Oja et al., 2016; PRIA, 2020, Suure et al., 2021).

The aim of this study is to develop remote sensing methods based on Estonian Land Board data, which could allow to take control over landscape features destructions and to provide reliable data for landscape elements analysis in Estonia. Secondary goal is to compare developed models' results. To achieve set goals rasters of DEM, nDSM with spatial resolution 1 m and orthophotos with pixel size of 0.25 m were used. Orthophotos were then converted into 1 m spatial resolution.

To start with, several derivatives of Digital Elevation Model were tested to enable detection of ditches. The most efficient derivative was topographic openness index. Then, two types of remote sensing models were developed. First one was based on map algebra as a non-complex and fast method. Second one was an object-based image analysis method utilizing machine learning classification for more detailed and precise detection. Both models were tested in 3 study areas in Estonia: Southern Estonia, Central Estonia and Saaremaa Island.

The first model was based on a combination of openness index and normalized digital surface model (nDSM) masks with assistance of additional buildings and agricultural land layers. This model resulted in 3 landscape element types: ditch, ditch covered by vegetation and vegetation patches. With high overall accuracy of 86.78% but lower user's and producer's accuracies it can be considered as a well suitable method for simple detection of changes in landscape elements. The model is computationally effective – less than 1 minute for 5 × 5 km map sheet.

Two datasets were used in the object-based model: 1) openness index + nDSM and 2) openness index + nDSM + NDVI. The developed object-based model consists of segmentation and two classification stages. During the first stage, segments were classified into vegetation, ditch and ditch covered by vegetation classes based on segment's spectral signatures. During the second stage, segments dissolved by predicted class were classified into linear vegetation patches,

vegetation islands on the field and ditches based on spectral properties and shape indices. The usage of NDVI did not lead to higher classification accuracies. Moreover, some classification accuracies were even notably higher using only elevation data. Overall accuracies up to 86.92%, similarly to map algebra model, prove that it is possible to detect landscape elements well. The highest producer's and user's accuracies were in field islands class 97.18% and 73.90% respectively and lowest in linear vegetation patches class – both under 40%. The computation of one 5×5 km map sheet with a developed model using only elevation dataset took up approximately 8.5 minutes. Elevation data + NDVI computation took up 11 minutes.

Advantages and disadvantages of pixel-based and object-based methods in this study correspond to other studies (Riggan & Weih, 2009; Whiteside et al., 2011). Both models have a potential to be enhanced and display more enhanced outcomes.

There is potential of those developed models to be utilized in landscape elements monitoring or in creation of landscape elements layer for further analysis.

Tänuavaldused

Suur tänu minu juhendajale Evelyn Uuemaale abivalmiduse, väärtuslike nõuannete ja pühendatud aja eest. Samuti olen tänulik Andres Kasekambale käesoleva tööga seotud nõuannete eest Maa-ameti suvepraktika käigus.

Kasutatud kirjandus

Blaschke, T., Lang, S., Lorup, E., Strobl, J. & Zeil, P., 2000. Object-Oriented Image Processing in an Integrated GIS/Remote Sensing Environment and Perspectives for Environmental Applications. 2.

Blaschke, T., 2010. Object based image analysis for remote sensing. ISPRS Journal of Photogrammetry and Remote Sensing, 65, pp. 2-16. DOI: <https://doi.org/10.1016/j.isprsjprs.2009.06.004>

Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L. & Lopez, A., 2020. A comprehensive survey on support vector machine classification: Applications, challenges and trends, Neurocomputing, 408, pp. 189-215, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2019.10.118>.

Clewley, D., Bunting, P., Shepherd, J., Gillingham, S., Flood, N., Dymond, J., Lucas, R., Armston, J. & Moghaddam, M., 2014. A Python-Based Open Source System for Geographic Object-Based Image Analysis (GEOBIA) Utilizing Raster Attribute Tables, Remote Sensing. 6. 6111-6135. 10.3390/rs6076111.

Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V. & Böhner, J., 2015. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, Geoscientific Model Development, 8, 1991-2007, doi:10.5194/gmd-8-1991-2015

Doneus, M., 2013. Openness as Visualization Technique for Interpretative Mapping of Airborne Lidar Derived Digital Terrain Models, Remote Sensing, 5, no. 12: 6427-6442. DOI: <https://doi.org/10.3390/rs5126427>

Foody, G. M., 2008. Harshness in image classification accuracy assessment, International Journal of Remote Sensing, 29:11, 3137-3158, DOI: 10.1080/01431160701442120

GISGeography 2022. What is NDVI (Normalized Difference Vegetation Index)?, <https://gisgeography.com/ndvi-normalized-difference-vegetation-index/> (viimati vaadatud 25.04.2022)

Grizonnet, M., Michel, J., Poughon, V., Inglada, J., Savinaud, M. & Cresson, R., 2017. Orfeo ToolBox: open source processing of remote sensing images. Open geospatial data, software and standards, 2, 15. <https://doi.org/10.1186/s40965-017-0031-6>

IBM 2022. K-Nearest Neighbors Algorithm, <https://www.ibm.com/topics/knn#:~:text=The%20k%2Dnearest%20neighbors%20algorithm%20C%20also%20known%20as%20KNN%20or,of%20an%20individual%20data%20point.,> (viimati vaadatud 10.05.2022)

Jeong, S. G., Mo, Y., Kim, H. G., Park, C. H. & Lee, D. K., 2016. Mapping riparian habitat using a combination of remote-sensing techniques, International Journal of Remote Sensing, 37:5, 1069-1088, DOI: 10.1080/01431161.2016.1142685

Johnson, B. A., & Lei M., 2020. Image Segmentation and Object-Based Image Analysis for Environmental Monitoring: Recent Areas of Interest, Researchers' Views on the Future Priorities, *Remote Sensing*, 12, no. 11: 1772. <https://doi.org/10.3390/rs12111772>

Kollar, S., Vekerdy, Z. & Markus, B., 2013. Aerial Image Classification for the Mapping of Riparian Vegetation Habitats. *Acta Silvatica & Lignaria Hungarica*, 9. 119-133, DOI: 10.2478/aslh-2013-0010.

Krause, A., Danes, M., Janssen, H., Kramer, H. & Rip, F., 2011. Recording small landscape features by object recognition; Possibilities and limitations of automated procedures to support monitoring in the frame of the GeoCAP. *Wageninge Alterra, Alterra-Report 2137*, 86 blz.; 28 fig.; 10 tab.; 31 ref.

Kucharczyk, M., Geoffrey J. H., Salar G. & Chris H. H., 2020. Geographic Object-Based Image Analysis: A Primer and Future Directions. *Remote Sensing*, 12, no. 12: 2012. <https://doi.org/10.3390/rs12122012>

Lucas, C., Bouten, W., Koma, Z., Kissling, W.D. & Seijmonsbergen, A. C., 2019. Identification of Linear Vegetation Elements in a Rural Landscape Using LiDAR Point Clouds. *Remote Sensing*, 11(3):292, DOI: <https://doi.org/10.3390/rs11030292>

Maa-amet 2022a. Avaleht, <https://maaamet.ee/>, (viimati vaadatud 18.03.2022)

Maa-amet 2022b. Eesti topograafia andmekogu – ETAK andmete vanus kaardiruutude kaupa, <https://geoportaal.maaamet.ee/est/Ruumiandmed/Eesti-topograafia-andmekogu-p79.html>, (viimati vaadatud 16.05.2022).

Maa-amet 2022c. Fotoladu - aerofotode digitaalarhiiv, <https://fotoladu.maaamet.ee/?basemap=hybriidk&zlevel=3,25.05578,58.81510&overlay=avaleht>, (viimati vaadatud 18.03.2022).

Maa-amet 2022d. Kõrgusmudelid, <https://geoportaal.maaamet.ee/est/Ruumiandmed/Korgusandmed/Korgusmudelid-p508.html>, (viimati vaadatud 06.04.2022)

Maa-amet 2022e. Ortofotod, <https://geoportaal.maaamet.ee/est/Ruumiandmed/Ortofotod-p99.html>, (viimati vaadatud 06.04.2022)

MacFaden, S.W., O'Neil-Dunne, J.P.M., Royar, A.R., Lu, J.W.T. & Rundle, A.G., 2012. High-resolution tree canopy mapping for New York City using LiDAR and object-based image analysis. *Journal of Applied Remote Sensing*, 6, doi:10.1117/1.JRS.6.063567.

Marja, R., Uuemaa, E., Mander, Ü., Elts, J. & Truu, J., 2013. Landscape pattern and census area as determinants of the diversity of farmland avifauna in Estonia. *Regional Environmental Change*, 13(5), 1013 - 1020 lk.

O'Neil-Dunne, J., Sean M. & Anna R., 2014. A Versatile, Production-Oriented Approach to High-Resolution Tree-Canopy Mapping in Urban and Suburban Landscapes Using GEOBIA and Data Fusion. *Remote Sensing*, 6, no. 12: 12837-12865. <https://doi.org/10.3390/rs61212837>

Oja, T., Uuemaa, E. & Mõisja, K., 2016. Eesti tingimustes oluliste maastikuelementide määratlemine ja olulisuse hindamine: aruanne. Tartu Ülikooli geograafia osakond, Tartu.

Peterson, U., Eerme, K., Lang, M., Nilson, T., Kuusk, A. & Väljataga, K., 2008. Kaugseire koht ja tähendus loodusandmete kogumises ning andmetöötuses. rmt: K. Väljataga & K. Kaukver, toim-d Kaugseire Eestis 2008. Tallinn: Tartu Observatoorium, pp. 8-17.

PRIA 2020. Abiks taotlejale: juhend, <https://www.pria.ee/sites/default/files/2020-04/Juhend%20Abiks%20taotlejale%202020%20%28%C3%9CPT%2C%20ROH%2C%20NPT%2C%20PKV%2C%20VPT%2C%20PTO%2C%20SEL%29.pdf> (viimati vaadatud 01.12.2021). Tallinn, Tartu

Põllumajanduse Registrite ja Informatsiooni Amet 2021. Avaleht, <https://www.pria.ee/>, (viimati vaadatud 16.05.2022)

Raczko, E. & Zagajewski, B., 2017. Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images, *European Journal of Remote Sensing*, 50:1, 144-154, DOI: 10.1080/22797254.2017.1299557

Radoux, J., Chomé, G., Jacques, D., Waldner, F., Bellemans, N., Matton, N., Lamarche, C., d'Andrimont, R. & Defourny, P., 2016. Sentinel-2's Potential for Sub-Pixel Landscape Feature Detection. *Remote Sensing*, 8, 488, 10.3390/rs8060488.

Riggan, N. D. Jr. & Weih, R. C. Jr., 2009. Comparison of Pixel-based versus Object-based Land Use/Land Cover Classification Methodologies. *Journal of the Arkansas Academy of Science*, vol. 63: 18.

Riigi Teataja. Maa heas põllumajandus- ja keskkonnaseisundis hoidmise nõuded. 2015. – Riigi Teataja RT I, 16.01.2015, 6

Rist, S., 2017. Mehitamata õhusõiduki abil loodud ortofotolt maakatte klassifitseerimine. Magistritöö. Tartu Ülikool, Tartu

SAGA 2020. Module Topographic Openness, https://saga-gis.sourceforge.io/saga_tool_doc/2.2.5/ta_lighting_5.html, (viimati vaadatud 15.03.2022)

Sébastien, L., Sheeren, D. & Tasar, O., 2019. A Generic Framework for Combining Multiple Segmentations in Geographic Object-Based Image Analysis. *ISPRS International Journal of Geo-Information*, 8, no. 2: 70. <https://doi.org/10.3390/ijgi8020070>

Shahab E., J., A. Johnson, B. & Chen, D., 2019. Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification. *Remote Sensing*, 11, no. 14: 1713. <https://doi.org/10.3390/rs11141713>

Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi P., & S. Homayouni, S., 2020. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13, pp. 6308-6325, doi: 10.1109/JSTARS.2020.3026724.

Shepherd, J. D., Pete B. & John R. D., 2019. Operational Large-Scale Segmentation of Imagery Based on Iterative Elimination. *Remote Sensing*, 11, no. 6: 658. <https://doi.org/10.3390/rs11060658>

Suure, S., Peepson, A., Mikk, M., Karjatse, M., Vallner-Kranich, V. & Vetemaa, A., 2021. Nõuetele vastavus ja rohestamine 2021. Ökoloogiliste Tehnoloogiate keskus koostöös Maaeluministeeriumiga. Tartu: Ecoprint

Tamm, T., Lang, M. & Metsur, M., 2014. Maa-ameti kaugseire andmete kasutamine ETAKi maakattetüüpide objektipõhisel tuvastamisel. rmt: A. Aan & K. Narusk, toim-d Kaugseire Eestis 2014. Tallinn: Tartu Observatoorium, pp. 104-110.

Trimble Germany GmbH, 2021. Trimble Documentation eCognition Developer 10.1 Reference Book; Trimble Germany GmbH: Munich, Germany.

Voormansik, V., 2016. Vöasastumise tõttu muutunud põllupiiride objektipõhine tuvastamine kaugseire andmetel. Magistritöö. Tartu Ülikool, Tartu

Whiteside, T. G., Boggs, G. S. & Maier, S., W., 2011. Comparing object-based and pixel-based classifications for mapping savannas. *International Journal of Applied Earth Observation and Geoinformation*, 13: 6, 884-893, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2011.06.008>.

Yokoyama, R., Shirasawa, M. & Pike, R.J., 2002. Visualizing topography by openness: A new application of image processing to DEMs. *Photogrammetric Engineering & Remote Sensing*, 68, 257-265.

Zagajewski, B., Kluczek, M., Raczko, E., Njegovec, A., Dabija, A. & Kycko, M., 2021. Comparison of Random Forest, Support Vector Machines, and Neural Networks for Post-Disaster Forest Species Mapping of the Krkonoše/Karkonosze Transboundary Biosphere Reserve. *Remote Sensing*, 13(13):2581. <https://doi.org/10.3390/rs13132581>

Zhao, W., Du, S. & Emery, W., 2017. Object-Based Convolutional Neural Network for High-Resolution Imagery Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10. 3386-3396. 10.1109/JSTARS.2017.2680324.

Zurqani, H.A., Post, C.J., Mikhailova, E.A., Cope, M.P., Allen, J.S., & Lytle, B.A., 2020. Evaluating the integrity of forested riparian buffers over a large area using LiDAR data and

Google Earth Engine. Scientific Reports, 10, 14096. DOI: <https://doi.org/10.1038/s41598-020-69743-z>

Lisad

Lisa 1. Maastikuelementide vahelised veamaatriksid üle Eesti. Read on referentsandmed, veerud – ennustatud alad. Numbrid veamaatriksis näitavad 1×1 m pikslite arvu.

TT – Tootjatäpsus

KaT – Kasutajatäpsus

KT – Kogutäpsus

LT – Lineaarne taimestikust maastikuelement

PS - Põllusaar

Saaremaa kaardialgebra					Kesk-Eesti kaardialgebra					Lõuna-Eesti kaardialgebra							
	Kraav	Taimestik	Kokku	TT		Kraav	Taimestik	Kokku	TT		Kraav	Taimestik	Kokku	TT			
Kraav	185621	20087	205708	90,24%	Kraav	117361	4355	121716	96,42%	Kraav	153415	10242	163657	93,74%			
Taimestik	25972	15917	41889	38,00%	Taimestik	21438	35698	57136	62,48%	Taimestik	2461	25383	27844	91,16%			
Kokku	211593	36004	247597		Kokku	138799	40053	178852		Kokku	155876	35625	191501				
KaT	87,73%	44,21%		KT: 81.38%	KaT	84,55%	89,13%		KT: 85,58%	KaT	98,42%	71,25%		KT: 93.37%			
Saaremaa 2B					Kesk-Eesti 2B					Lõuna-Eesti 2B							
	LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT
LT	1125	0	0	1125	100,00%	LT	9923	2131	546	12600	78,75%	LT	5073	514	1185	6772	74,91%
PS	8454	22926	12518	43898	52,23%	PS	2700	33742	10816	47258	71,40%	PS	7235	7148	981	15364	46,52%
Kraav	26016	7286	135508	168810	80,27%	Kraav	2189	2511	96662	101362	95,36%	Kraav	8686	6348	140166	155200	90,31%
Kokku	35595	30212	148026	213833		Kokku	14812	38384	108024	161220		Kokku	20994	14010	142332	177336	
KaT	3,16%	75,88%	91,54%		KT: 74.62%	KaT	66,99%	87,91%	89,48%		KT: 87,04%	KaT	24,16%	51,02%	98,48%		KT: 85,93%
Saaremaa 2B*					Kesk-Eesti 2B*					Lõuna-Eesti 2B*							
	LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT
LT	1125	0	0	1125	100,00%	LT	7871	4246	444	12561	62,66%	LT	5239	1041	1104	7384	70,95%
PS	1328	45516	259	47103	96,63%	PS	137	47952	1023	49112	97,64%	PS	319	16340	138	16797	97,28%
Kraav	25737	15064	125690	166491	75,49%	Kraav	1969	4820	93942	100731	93,26%	Kraav	9653	8773	136987	155413	88,14%
Kokku	28190	60580	125949	214719		Kokku	9977	57018	95409	162404		Kokku	15211	26154	138229	179594	
KaT	3,99%	75,13%	99,79%		KT: 80.26%	KaT	78,89%	84,10%	98,46%		KT: 92,22%	KaT	34,44%	62,48%	99,10%		KT: 88,29%
Saaremaa 3B					Kesk-Eesti 3B					Lõuna-Eesti 3B							
	LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT
LT	1125	0	0	1125	1	LT	7328	4210	669	12207	60,03%	LT	4709	308	1146	6163	76,41%
PS	1182	26889	12876	40947	0,656678	PS	2822	32612	9594	45028	72,43%	PS	7101	7177	605	14883	48,22%
Kraav	24954	22082	120117	167153	0,718605	Kraav	2210	1947	97133	101290	95,90%	Kraav	7374	8706	139510	155590	89,67%
Kokku	27261	48971	132993	209225		Kokku	12360	38769	107396	158525		Kokku	19184	16191	141261	176636	
KaT	0,041268	0,54908	0,903183		KT: 70,80%	KaT	59,29%	84,12%	90,44%		KT: 86,47%	KaT	24,55%	44,33%	98,76%		KT: 85,71%
Saaremaa 3B*					Kesk-Eesti 3B*					Lõuna-Eesti 3B*							
	LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT		LT	PS	Kraav	Kokku	TT
LT	1125	0	0	1125	100,00%	LT	7525	4931	99	12555	59,94%	LT	5311	563	1239	7113	74,67%
PS	0	49305	188	49493	99,62%	PS	240	47303	1095	48638	97,26%	PS	2924	14055	10	16989	82,73%
Kraav	23170	22327	120280	165777	72,56%	Kraav	2140	5106	92847	100093	92,76%	Kraav	7388	7646	142406	157440	90,45%
Kokku	24295	71632	120468	216395		Kokku	9905	57340	94041	161286		Kokku	15623	22264	143655	181542	
KaT	4,63%	68,83%	99,84%		KT: 78.89%	KaT	75,97%	82,50%	98,73%		KT: 91,56%	KaT	33,99%	63,13%	99,13%		KT: 89,11%

Lisa 2. Maastikuelementide indikatiivsed veamaatriksid üle Eesti. Read on referentsandmed, veerud – ennustatud alad. Numbrid veamaatriksis näitavad 1×1 m pikslite arvu.

TT – Tootjatäpsus

KaT – Kasutajatäpsus

KT – Kogutäpsus

ME - Maastikuelement

Saaremaa kaardialgebra					Kesk-Eesti kaardialgebra					Lõuna-Eesti kaardialgebra				
	Muu	ME	Kokku	TT		Muu	ME	Kokku	TT		Muu	ME	Kokku	TT
Muu	23535087	1178418	24713505	95,23%	Muu	24074110	721863	24795973	97,09%	Muu	23621428	1142151	24763579	95,39%
ME	41339	245156	286495	85,57%	ME	25646	178381	204027	87,43%	ME	44920	191501	236421	81,00%
Kokku	23576426	1423574	25000000		Kokku	24099756	900244	25000000		Kokku	23666348	1333652	25000000	
KaT	99,82%	17,22%		KT: 95,12%	KaT	99,89%	19,81%		KT: 97,01%	KaT	99,81%	14,36%		KT: 95,25%
Saaremaa 2B					Kesk-Eesti 2B					Lõuna-Eesti 2B				
	Muu	ME	Kokku	TT		Muu	ME	Kokku	TT		Muu	ME	Kokku	TT
Muu	24090596	622909	24713505	97,48%	Muu	24453958	342015	24795973	98,62%	Muu	24041973	721606	24763579	97,09%
ME	75162	211333	286495	73,76%	ME	43355	160672	204027	78,75%	ME	59085	177336	236421	75,01%
Kokku	24165758	834242	25000000		Kokku	24497313	502687	25000000		Kokku	24101058	898942	25000000	
KaT	99,69%	25,33%		KT: 97,21%	KaT	99,82%	31,96%		KT: 98,46%	KaT	99,75%	19,73%		KT: 96,88%
Saaremaa 2B*					Kesk-Eesti 2B*					Lõuna-Eesti 2B*				
	Muu	ME	Kokku	TT		Muu	ME	Kokku	TT		Muu	ME	Kokku	TT
Muu	24144680	568825	24713505	97,70%	Muu	24449079	346894	24795973	98,60%	Muu	24002076	761503	24763579	96,92%
ME	74400	212095	286495	74,03%	ME	42190	161837	204027	79,32%	ME	56827	179594	236421	75,96%
Kokku	24219080	780920	25000000		Kokku	24491269	508731	25000000		Kokku	24058903	941097	25000000	
KaT	99,69%	27,16%		KT: 97,43%	KaT	99,83%	31,81%		KT: 98,44%	KaT	99,76%	19,08%		KT: 96,73%
Saaremaa 3B					Kesk-Eesti 3B					Lõuna-Eesti 3B				
	Muu	ME	Kokku	TT		Muu	ME	Kokku	TT		Muu	ME	Kokku	TT
Muu	24091853	621652	24713505	97,48%	Muu	24470695	325278	24795973	98,69%	Muu	24102227	661352	24763579	97,33%
ME	79711	206784	286495	72,18%	ME	46116	157911	204027	77,40%	ME	59785	176636	236421	74,71%
Kokku	24171564	828436	25000000		Kokku	24516811	483189	25000000		Kokku	24162012	837988	25000000	
KaT	99,67%	24,96%		KT: 97,19%	KaT	99,81%	32,68%		KT: 98,51%	KaT	99,75%	21,08%		KT: 97,12%
Saaremaa 3B*					Kesk-Eesti 3B*					Lõuna-Eesti 3B*				
	Muu	ME	Kokku	TT		Muu	ME	Kokku	TT		Muu	ME	Kokku	TT
Muu	24039490	674015	24713505	97,27%	Muu	24449305	346668	24795973	98,60%	Muu	24045149	718430	24763579	97,10%
ME	72542	213953	286495	74,68%	ME	43427	160600	204027	78,72%	ME	54879	181542	236421	76,79%
Kokku	24112032	887968	25000000		Kokku	24492732	507268	25000000		Kokku	24100028	899972	25000000	
KaT	99,70%	24,09%		KT: 97,01%	KaT	99,82%	31,66%		KT: 98,44%	KaT	99,77%	20,17%		KT: 96,91%

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Nikita Murin,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose „Maastikuelementide tuvastamine kaugseire abil“, mille juhendaja on PhD Evelyn Uuemaa, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada digitaalarhiivi DSpace kuni autoriõiguse kehtivuse lõppemiseni.
2. Annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi DSpace kaudu Creative Commons'i litsentsiga CC BY NC ND 4.0, mis lubab autorile viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni.
3. Olen teadlik, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autorile.
4. Kinnitan, et lihtlitsentsi andmisega ei riku ma teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

Nikita Murin

29.05.2022