

Tartu Ülikool

Loodus- ja täppisteaduste valdkond

Ökoloogia ja maateaduste instituut

Geograafia osakond

Magistritöö geoinformaatikas ja kartograafias 30 EAP

**Võsastumise tõttu muutunud põllupiiride objektipõhine  
tuvastamine kaugseire andmetel**

Villem Voormansik

Juhendajad: MSc Tanel Tamm

MSc Martin Jüssi

Kaitsmisele lubatud:

Juhendajad:

Osakonna juhataja:

Tartu 2016

## **Annotatsioon**

### **Võsastumise tõttu muutunud põllupiiride objektipõhine tuvastamine kaugseire andmetel**

Käesoleva töö eesmärk on kahest lähteandmete komplektist tuvastada objektipõhise meetodikaga võsastumise tõttu muutunud põllupiirid ning tulemusi omavahel võrrelda. Lähteandmeteks olid ainult normaliseeritud maakatte kõrgusmudel (nDSM) ning nDSM koos optiliste NDVI ja NDWI andmekihtidega. Kummalgi juhul saavutati kõrge võsa klassifitseerimistäpsus: kogutäpsus = 0,96, Kapa koefitsient = 0,91. Tuletatud põllupiirid asusid etalonpiirist keskmiselt 0,69 m kaugusel ning umbes 80% piiri pikkusest asus etalonile lähemal kui 1 m. Kohati erinesid tulemused visuaalsel analüüsil. Kõrgusmudelitest ning optilistest andmetest arvatud põllupiiridele oli iseloomulik keerulisem piirjoon ning see osutus täpsemaks madala ja laiguti esineva võsaga aladel.

Märksõnad: objektipõhine pildianalüüs, kaugseire, ortofoto, aerolaserskaneerimine, LiDAR, põllumajandusmaa, maakattetüüpide klassifitseerimine, muutuste tuvastamine

CERCS T181 kaugseire

### **Object-based mapping of secondary forest succession on agricultural land with remote sensing data**

The aim of this study is to map secondary forest succession on agricultural land using two sets of source data and to compare the results. First, normalised digital surface model (nDSM) and secondly, the same nDSM with optical NDVI and NDWI data layers were used as the data sets. Classification accuracy was high in both cases as overall accuracy of 0,96 and Kappa of 0,91 was achieved. The average distance between both of the resulting arable land borders and the reference border was 0,69 m. About 80% of the length of the borders was closer than 1 m to the reference border. Visual analysis revealed some differences between the results. Borders derived from nDSM with optical data tended to have more complex edges and better accuracy on shrublands or areas only partly covered with brushwood.

Keywords: object-based image analysis, remote sensing, orthophoto, airborne laser scanning, LiDAR, arable land, land cover classification, change detection

CERCS T181 remote sensing

# Sisukord

Sissejuhatus .....	4
1. Objektipõhine pildianalüüs kaugseires .....	6
1.1. Objektipõhise pildianalüüsi alused .....	6
1.2. Segmenteerimisalgoritm <i>multiresolution segmentation</i> .....	8
1.3. Varasemad tööd objektipõhise kaugseire ja võsastumise teemadel .....	10
2. Uurimisala ja andmed .....	13
2.1. Uurimisala .....	13
2.2. Andmed .....	14
2.2.1. ALS andmed .....	14
2.2.2. Ortofotod .....	14
2.2.3. Põldude vektorkiht .....	15
2.2.4. Maastikuelementide vektorkiht .....	16
3. Metoodika .....	18
3.1. Tugivektormasina treenimine .....	18
3.2. Segmenteerimine ja klassifitseerimine .....	20
3.3. Eksportimine .....	22
3.4. Klassifitseerimis- ja asukohatäpsuse hindamine .....	22
4. Tulemused ja arutelu .....	24
4.1. Kirjeldav analüüs .....	24
4.2. Võsaproductide klassifitseerimistäpsus .....	28
4.3. Põllupiiride joontel põhinevad võrdlused etaloniga .....	29
Kokkuvõte .....	32
Summary .....	34
Tänuavaldused .....	36
Kasutatud kirjandus .....	37
Lisad .....	40

## Sissejuhatus

Eestis oli Statistikaameti (2016) andmetel 2014. aastal 974 820 ha kasutatavat põllumajandusmaad. Suurjärvi arvestamata moodustab see 22,4% Eesti pindalast. Põllumajandusega seotud riiklike registrite pidamise kohustus on Eesti Vabariigi Maaeluministeeriumi valitsemisalas oleval Põllumajanduse Registrite ja Informatsiooni Ametil (PRIA). Registrite pidamine tähendab muuhulgas põldude ruumikuju andmete haldamist ja regulaarset uuendamist. Ruumikuju on vaja teada ka pindalatoetuste määramisel. Pindalatoetused on taimekasvatuse valdkonna toetused, mis olenevad põllumajandusliku maa pindalast ja mille eesmärgiks on muuhulgas põllumajandustootmise ja maa hoolduskulude hüvitamine (PRIA, 2016). PRIA-s uuendatakse ja kontrollitakse põllupiiride andmeid mõõtmistega välitöödel ja käsitsi digitaliseerimisega kaugseireandmetelt. Töö efektiivsuse suurendamiseks ja kulude kokkuhoiduks oleks kasu põldude ruumiandmete haldamise ulatuslikumast automatiseerimisest.

Põllumaa piirid võivad muutuda näiteks maakasutuse muutuse tagajärjel või uute rajatiste (teed, hooned, piirded, kraavid jms) tõttu. Üheks sagedasemaks piiride muutumise põhjuseks on võsastumine (Hellesten & Matikainen, 2013; Tamm, 2014; Kolecka jt, 2015). Käesoleva töö eesmärk on töötada välja objektipõhine meetodika võsastumise tõttu muutunud põllupiiride tuvastamiseks, rakendada seda kahe lähteandmete komplektiga ning võrrelda tulemusi omavahel. Kasutatavad lähteandmete komplektid olid:

- ainult aerolaserskaneerimise andmed;
- aerolaserskaneerimise andmed koos optiliste kaugseireandmetega.

Otsiti võimalikult täpset põldude piiritlemist võsa või muu kõrge puittaimestikuga külgnemisel ning samal ajal võimalikult suurt automatiseeritust. Terminit „võsa“ kasutatakse käesolevas töös igasuguse põllumajandustegevust takistava puittaimestiku tähenduses, hõlmates sealhulgas ka mõiste „mets“ tähenduse.

Aerolaserskaneerimisest saadud kõrgusandmed on võsa piiritlemiseks väga efektiivne andmestik (Lang, 2013; Hellesten & Matikainen, 2013; Kolecka jt, 2015). Puuduseks on aga tavaliselt optilistest andmetest madalam resolutsioon ning kasinam spektraalne info. Kahest erinevast lähteandmete komplektist saadud tulemuste võrdlemine aitab vastata küsimusele, kas täiendavad andmed avaldavad klassifitseerimise ja piiride täpsusele olulist mõju.

Tulemusi võrreldi nii kvantitatiivsest kui ka kvalitatiivsest aspektist. Arvutati võsa klassifitseerimistäpsuse hinnangud ning põllupiiride täpsust võrreldi joontel põhinevate asukohatäpsuse hindamise meetoditega. Laiapõhjalisemaks võrdluseks analüüsiti tulemusi ka visuaalse vaatluse põhjal.

# 1. Objektipõhine pildianalüüs kaugseires

## 1.1. Objektipõhise pildianalüüsi alused

Kaugseire on üks olulisemaid ruumiandmete allikaid (Eastman, 2006). Toored kaugseirekujutised ei sisalda peaaegu kunagi andmeid vajalikul kujul. Olulise info kätte saamiseks tuleb andmeid töödelda. Tihti on soovitud andmeteks sisulise tähendusega klassid, näiteks maakattetüübid. Protsessi selliste klasside saamiseks nimetatakse klassifitseerimiseks.

Traditsiooniliselt on klassifitseerimisülesannet lahendatud üksnes kujutise vähima elemendi, piksli, omadusi kasutades. Pikslipõhine klassifitseerimine on efektiivne, kui andmete ruumiline lahusus on uuritavate objektidega samas suurusjärgus (Blaschke, 2010). Kaugseireinstrumentide ruumilise lahutuse paranedes on pikslid muutunud objektidest palju väiksemaks. Eesti Maa-ameti toodetud ortofotode piksli suurus on 25 cm (Maa-amet, 2015a), tiheasustusaladel aga 10, 12,5 või 16 cm (Maa-amet, 2015b). Väiksemad pikslid ei kirjelda reeglina enam objekti kui terviku keskmist väärtust, vaid selle seesmist heterogeensust. Seetõttu ei kaasne kõrgema ruumilise lahtusvõimega paremat klassifitseerimistäpsust (Hay & Castilla, 2008; Malinverni jt, 2011).

Lahendus on leitud pikslite konteksti arvestamises. Piksleid vaadeldakse mitte üksikult, vaid koos naabrusega, pikslite kogumitena. Nii saab arvesse võtta muuhulgas tekstuuri, kuju või statistilisi arvvaartusi. Erinevus on niivõrd põhimõtteline, et seda võib pidada paradigmapuhetuseks (Hay & Castilla, 2008; Blaschke, 2010).

Kirjeldatud põhimõtet rakendavate meetodite keskne mõiste on objekt – kokku kuuluvad pikslid moodustavad pildiobjekti (ingl *image object*). Pildiobjektid üritatakse piiritleda võimalikult täpses vastavuses reaalsete objektidega. Sellest tuleneb koondnimetus objektipõhine pildianalüüs. Ingliseelse termini *object-based image analysis* järgi on kasutuses lühend OBIA. Kasutatakse ka lühendit GEOBIA (*Geographic Object-Based Image Analysis*), eriti siis, kui kontekstist ei ole selge, et peetakse silmas geograafilist ruumi ja geoinfoteaduse (*GIScience*) haru.

OBIA ülim eesmärk on inимtaju-sarnane objektide interpreteerimine (Lang, 2008). On teada, et inimesed eristavad kujutise analüüsimisel intuiitiivselt objekte, kasutades informatsiooni suuruse, tekstuuri, kuju, paiknemise jm kohta, mitte ei keskendu vähimatele detailidele üksikult (Hussain jt, 2013). Inimtajule analoogselt üritatakse pilt jagada tähenduslikeks objektideks. Objektipõhise pildianalüüsi võtmetähtsusega tegevuseks on segmenteerimine,

mille tulemusel jaotatakse kujutis mitmetest pikslitest koosnevateks segmentideks (Lang, 2008). Segment on kujutise osa, mis on tunnusruumi ühe või mitme kriteeriumi järgi seesmiselt koherentne (Blaschke, 2010). Segmendid moodustavad täieliku tessellatsiooni – iga punkt kujutisel kuulub mingisse segmenti.

Segmente on kutsutud objektikandidaatideks (Burnett & Blaschke, 2003). See viitab, et potentsiaalselt vastab ühele segmendile või segmentide grupile geograafiline objekt. Segmentide liitmisel saadakse semantiliselt tähenduslikud objektid – maja, metsatukk või põld. Segmentide sidumist tähendusega nimetatakse klassifitseerimiseks. Segmenteerimine vähendab kujutise keerukust, muutes selle sisu paremini hoomatavaks (Lang, 2008).

Kuna segmendid koosnevad hulgast pikslitest, siis saab neid iseloomustada suurema hulga parameetritega kui üksikuid piksleid. Täiendavatest spektraalsetest parameetritest olulisemaks peetakse lisandunud ruumilisi parameetreid (Blaschke, 2010). Need võivad olla seotud näiteks kauguse, topoloogia, kuju, naabruse või hierarhiaga (Lang, 2008).

Kaks OBIA olulisemat sammu – segmenteerimine ja segmentide klassifitseerimine – ei moodusta lineaarset töövoogu, vaid iteratiivselt läbitava tsükli, milles kumbki on omavahel seotud (Lang, 2008). Sageli tuleb tulemuste parandamiseks tagasi pöörduda ja parameetreid optimeerida. Blaschke (2010) järgi on juba alates 2005. aastast OBIA olulisemaid trende töövoos suurem automatiseeritus, mitte enam segmenteerimisalgoritmide täiustamine. Täieliku automatiseerituseni ei ole siiski veel jõutud.

Geograafiliste nähtuste uurimisel on oluline arvestada skaalaga – tulemused olenevad mõõtkavast, mõõtühikutest ja generaliseerimisastmest (Marceau & Moreno, 2008) ega pruugi kõikidel skaaladel avalduda (Marceau, 1999). Niinimetatud skaalaprobleemile juhtisid esmalt tähelepanu inimgeograafid ja sotsiaalteadlased juba 20. sajandi esimeses pooles (Marceau, 1999). Üheks lahenduseks skaalaprobleemile on multiskaalaanalüüs (*multi-scale analysis*) (Marceau & Moreno, 2008). OBIA kontekstis tähendab see erinevate skaaladega kohanduvaid või kohandatavaid segmenteerimisalgoritme, näiteks järgmises peatükis tutvustatav *multiresolution segmentation*.

Arvutinägemine (*computer vision*) ning biomeditsiiniline pildianalüüs (*biomedical picture analysis*) on distsipliinid, mis tegelevad GEOBIA-ga sarnaste probleemidega. Erinevalt nendest tuleb GEOBIA-s arvestada geograafiliste nähtuste eripäraga. Peamisteks eripäradeks on hägusad piirid ja üleminekud olemite vahel, tüüpilise kuju puudumine, mitteühene

defineeritus, piltide multispektraalne ning mitmetasandiline (*multi-scale*) iseloom (Hay & Castilla, 2008). Hay ja Castilla (2008) selgitavad ühtlasi, millised n-ö tavaliste pildiobjektide omadused peavad olema ka geograafilistel pildiobjektidel:

- üheselt määratud diskreetne piir;
- seesmine koherentsus. Objekt ei pea olema seesmiselt homogeenne, kuid mingi näitaja poolest ühetaoline;
- kontrastsus ümbritsevaga, et eristatav ala moodustaks selgelt tajutava eraldi olemit.

Osutub, et tegelike geograafiliste objektide ja neid kujutavate pildiobjektide omaduste vahel on olulisi lahknevusi. Näiteks tegelikkuses ebaselgete piirjoontega ala tuleb pildiobjektina konkreetset piiritleda. Kuna kaugseireandmed on reaalse maailma enamasti kahemõõtmeline abstraktsioon ja lihtsus, ei ole pildiobjektide sidumine vastavate reaalsete objektidega alati üks-ühele võimalik. Praktikas ei esinda enamik segmente tähenduslikke geograafilisi objekte (Hay & Castilla, 2008). Vastavuse parandamiseks tuleb klassifitseerimise järel konkreetsele ülesandele kohandatud eeskirja järgi segmente liita.

OBIA kontseptsioon hakkas laialdaselt levima 2000. aasta paiku, kui ilmus esimene edukas OBIA põhimõtteid rakendav kommertstarkvara Definiens eCognition (Blaschke jt, 2008). Siiski ulatub idee ajalugu kaugemas minevikku. OBIA tugineb varasematele segmenteerimis-, servatuvastus- ja klassifitseerimispõhimõtetele 1970. aastatest (Blaschke, 2010). Üheks varasemaks sellelaadseks uurimuseks saab pidada Haralicki jt (1973) artiklit, mis kirjeldab 1 : 20 000 pankromaatilise aerofoto ning kaugseiresatelliidi Earth Resources Technology Satellite (ERTS) ehk Landsat-1 multispektraalsete piltide klassifitseerimist tekstuuri abil. Objektipõhise lähenemise viimasel ajal saavutatud populaarsus põhineb korraga nii vastava funktsionaalsusega võimeka kommertstarkvara olemasolul kui ka kõrge ruumilise lahutusega andmete laial levikul (Blaschke, 2010). OBIA eeliseid kõrge ruumilise lahutusega andmete töötlemisel on selgitatud peatüki alguses.

## **1.2. Segmenteerimisalgoritm *multiresolution segmentation***

Kuna segmenteerimine on objektipõhise pildianalüüsi olulisemaid alustalasid, antakse alljärgnevalt selle paremaks mõistmiseks ülevaade ühest levinud segmenteerimisalgoritmist. Tarkvara eCognition Developer *multiresolution segmentation* (MRS) algoritmi kasutati kaugseirepiltide segmenteerimiseks ka käesolevas töös.

MRS algoritmist on ülevaate andnud Baatz ja Schäpe (2000) ning Benz jt (2004). Segmenteerimist võib käsitleda optimeerimisülesandena, mille eesmärgiks on piiritleda etteantud parameetrite järgi võimalikult koherentsed objektid. Segmentide genereerimist saab juhtida läbi kolme parameetri: skaala (*scale*), kuju (*shape*) ja kompaktsus (*compactness*). Kaalude abil saab määrata, milliseid andmekihte ja kui suurel määral segmenteerimisel arvestatakse.

MRS põhineb alt üles (*bottom-up*) lähenemisel, kuna alustatakse ühe piksli suuruste objektidega, mida sobivuse järgi liidetakse üha järgmiste naaberobjektidega. Saadakse järjest suuremad objektid. Sobivuse mõõduks on heterogeensuse kasv  $f$  kahe objekti liitmisel. See on defineeritud spektraalse heterogeensuse muudu  $\Delta h_{värv}$  ja kuju heterogeensuse muudu  $\Delta h_{kuju}$  järgi (Benz, et al., 2004):

$$f = w_{värv} \cdot \Delta h_{värv} + w_{kuju} \cdot \Delta h_{kuju} \quad (1),$$

kus spektraalsusele ning kujule kehtestatud kaalud  $w_{värv}$  ja  $w_{kuju}$  vastavad tingimustele

$$w_{värv} \in [0, 1], w_{kuju} \in [0, 1], w_{värv} + w_{kuju} = 1.$$

Liitmiseks otsitakse kaht sellist naaberobjekti, mille liitmisel kasvab heterogeensus ( $f$ ) kõige vähem. Selleks leitakse heterogeensuse kasv kõigi liitmiskandidaatide kohta. Liidetakse sellised objektid, mis on vastastikku teineteise parimad liitmiskandidaadid. Nii tagatakse, et kõrge heterogeensusega objektile ei liideta madala heterogeensusega objekti ja lõplikud objektid on seesmiselt ühtlase kvaliteediga.

Kogu pildi ulatuses ühtlase suurusega objektide saavutamiseks valitakse objektide liitmise järjekord selliselt, et iga järgmine liitmine toimuks kõigist varem toimunud liitmistest võimalikult kaugel.

Objekte liidetakse seni, kuni enam ei leidu ühtegi kandidaati, mille liitmine ei ületaks lubatud heterogeensuse läve. Läviväärtuse määrab skaala parameetri väärtus. Mida suurem skaala väärtus, seda enam saab objekte liita ja seda suuremad on lõplikud objektid. Siit tuleb ka sõna *multiresolution* algoritmi nimetusse – *scale*’i väärtuse muutmise saad sama tööriistaga piiritleda erinevates mõõtkavades objekte.

Heterogeensuse kasvu valemis (1) esinev spektraalse heterogeensuse muut  $\Delta h_{värv}$  on defineeritud järgmiselt (Benz jt, 2004):

$$\Delta h_{\text{värv}} = \sum_c w_c \left( n_{\text{liidetud}} \cdot \sigma_{c,\text{liidetud}} - (n_{\text{obj1}} \cdot \sigma_{c,\text{obj1}} + n_{\text{obj2}} \cdot \sigma_{c,\text{obj2}}) \right) \quad (2),$$

kus  $n_{\text{liidetud}}$  on pikslite arv liidetud objektis,  $n_{\text{obj1}}$  ja  $n_{\text{obj2}}$  vastavalt pikslite arv esimeses ja teises objektis enne liitmist ning  $\sigma_c$  standardhälve kanalil  $c$ . Seega põhineb spektraalne heterogeensus standardhälvel, mida korrigeeritakse objekti suurusega.

Kuju heterogeensus muut võtab arvesse nii karedust (*smoothness*) kui kompaktsust (Benz jt, 2004):

$$\Delta h_{\text{kuju}} = w_{\text{kompaktsus}} \cdot \Delta h_{\text{kompaktsus}} + w_{\text{karedus}} \cdot \Delta h_{\text{karedus}} \quad (3)$$

Kompaktsus on defineeritud objekti übermõõdu  $l$  ja pikslite arvu  $n$  ruutjuure suhte järgi (Benz jt, 2004):

$$\Delta h_{\text{kompaktsus}} = n_{\text{liidetud}} \cdot \frac{l_{\text{liidetud}}}{\sqrt{n_{\text{liidetud}}}} - \left( n_{\text{obj1}} \cdot \frac{l_{\text{obj1}}}{\sqrt{n_{\text{obj1}}}} + n_{\text{obj2}} \cdot \frac{l_{\text{obj2}}}{\sqrt{n_{\text{obj2}}}} \right) \quad (4)$$

Karedus leitakse objekti übermõõdu  $l$  ja rastri telgede suhtes paralleelse vähima ümbritseva ristküliku übermõõdu  $b$  suhtena (Benz jt, 2004):

$$\Delta h_{\text{karedus}} = n_{\text{liidetud}} \cdot \frac{l_{\text{liidetud}}}{b_{\text{liidetud}}} - \left( n_{\text{obj1}} \cdot \frac{l_{\text{obj1}}}{b_{\text{obj1}}} + n_{\text{obj2}} \cdot \frac{l_{\text{obj2}}}{b_{\text{obj2}}} \right) \quad (5)$$

Kuju kriteerium aitab tagada ühtlasemaid ja lihtsama piiriga servasid, seda eriti spektraalselt väga varieeruvates piirkondades.

MRS-i protsessi iga etapp oleneb juba tekitatud objektidest ning lõpptulemus ei ole igal korral täielikult identne (Baatz & Schäpe, 2000). Erinevused on tavaliselt väga väikesed ja seisnevad madala kontrastsusega objektide piiride muutlikkuses.

### 1.3. Varasemad tööd objektipõhise kaugseire ja võsastumise teemadel

Robertson ja King (2011) võrdlesid maakattetüüpide piksli- ja objektipõhist klassifitseerimist. Kasutati Landsat Thematic Mapper 5 satelliidifotosid piksli suurusega 30 m. Meetodite täpsuse vahel ei leitud statistiliselt olulist erinevust. Objektipõhine klassifitseerimine oli ebatäpsem haruldaste ning väikese pindalaga maakattetüüpide korral. Leiti, et objektipõhise klassifitseerimise tulemus on kergemini interpreteeritav ja realistlikum, kuna maakattetüüpide piirid olid ühtlasemad ja paremas vastavuses reaalsusega. Käesoleva töö autor oletab, et meetodite täpsus ei erine oluliselt seetõttu, et kasutati madala resolutsiooniga andmeid.

Objektipõhiseid meetodeid kasutatakse tavaliselt lokaalse ulatusega uuringutes (Lu jt, 2011) ning sel juhul on sageli eelistatud kõrgem ruumiline lahutus.

Kõrgema ruumilise lahutusega andmete piksli- ja objektipõhist klassifitseerimistäpsust Corine maakattetüüpide eristamisel võrdlesid Malinverni jt (2011). Kasutati Leica ADS40 1 m ruumilise lahutusega andmeid. Maakattetüübid klassifitseeriti esmalt pikslipõhise klassifitseerijaga, saades täpsuseks 74%. Esialgse klassifitseerimistulemuse parandamisel objektipõhise lähenemisega suurenes täpsus 89%-ni.

Kolecka jt (2015) uurisid Poola Karpaatides sööti jäänud põldude võsastumist lidarandmestikuga (minimaalselt 4 punkti/m<sup>2</sup>). Täiendava andmekihina kasutati topograafilisi vektorandmeid, et eemaldada võsastunud aladele sarnased maakattetüübid, millel tegelikult on teistsugune funktsioon. Kasutati OBIA meetodeil põhinevat automaatset klassifitseerimist. Selleks arvutati taimkatte kõrguse ning katvuse mudelid. Rõhutati, et sobilike segmenteerimise parameetriteni jõuti katse ja eksituse meetodil, kontrollides vahetulemusi ortofotodelt – seni puudub üldiselt aktsepteeritav ühtne meetodika parameetrite väärtuste juhtimiseks. Leiti, et võsastunud on 79% uurimisalast, mis on oluliselt rohkem kui ametlike andmete pakutud 68%. Kontrollil maapinnalt tehtud maastikufotodega saadi täpsuseks 95,0%.

Puude võrade vaheliste tühimike segmenteerimise ja klassifitseerimise näite varal uurisid Yang jt (2015) optiliste ja lidarandmete kooskasutust. Leiti, et kasutades segmenteerimiseks ainult lidarandmeid, joonistuvad võrade vahelised tühimikud välja kõige paremini. Klassifitseerimisel osutus aga kasulikuks kasutada mõlemat andmestikku koos. Kooskasutusel saavutati kogutäpsus 80,28% ± 6,16%, optiliste andmetega 68,54% ± 9,03% ning lidariga 64,51% ± 11,32%. Leiti tugev seos segmenteerimise kvaliteedi ja klassifitseerimistäpsuse vahel.

Nii objektipõhise pildianalüüsi kui ka lidar- ja optilise andmestiku kooskasutuse piirangutele juhivad tähelepanu Chen jt (2011). Uurimuses arvutati QuickBirdi andmetest metsa kõrgus ning võrreldi lidarandmetest tuletatud kõrgusega. Koostati mitu GEOBIA-l põhinevat mudelit, mis erinesid objektide keskmise suuruse poolest. Väikseimaks suuruseks määrati 0,04 ha, kuna lidari ja optilise kaugseiresüsteemi kujutise moodustamise geometria erinevad üksteisest. Sellest põhjustatud suurimad erinevused andmetes esinevad piirkondades, kus lühikese plaanilise kauguse kohta on suur varieeruvus suhtelises kõrguses. Alla 0,04 ha suurused objektid olid kohati tugevalt mõjutatud andmekihtide omavahelisest ruumilisest sobimatuses. Leiti, et parimad GEOBIA-l põhinevad mudelid on pikslipõhistest täpsemad,

kuid GEOBIA täpsus on tugevalt sõltuv valitud objektide skaalast. Ebaõnnestunud skaalavalik võib täpsuse viia pikslipõhise lähenemisega saavutatust väiksemaks.

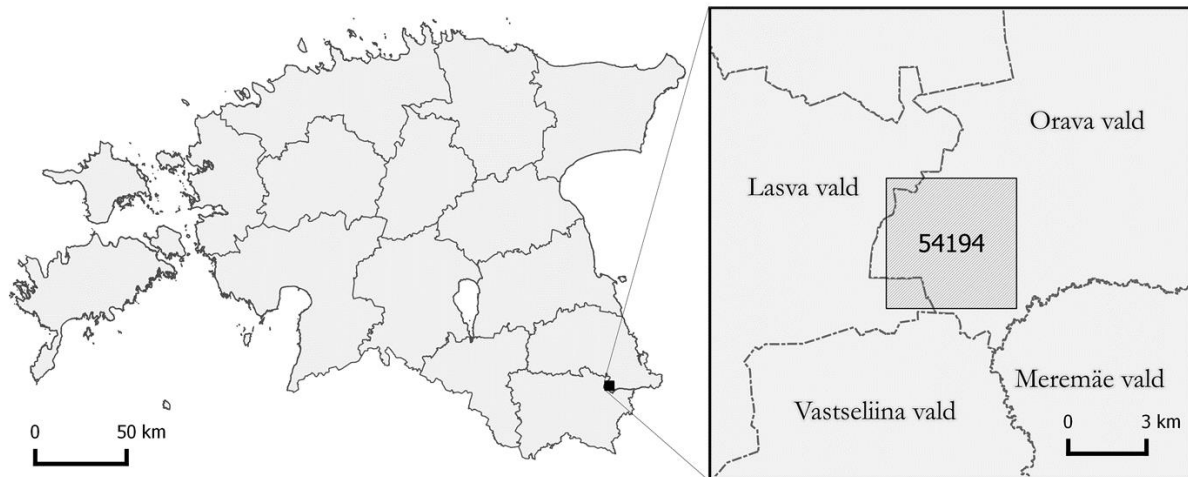
Käesoleva uurimistööga väga sarnast probleematikat käsitleb Tamm (2014) enda magistritöös. Töö eesmärgiks oli aerolaserskaneerimise (ALS) andmetel tuvastada võsastunud põllumaa Ahja vallas. Selleks arvutati normaliseeritud digitaalne pinnamudel (nDSM) resolutsiooniga  $5 \times 5$  m. Võrdluseks digitaliseeriti ortofotode järgi võsastunud alad põllumaal. Leiti, et ALS-andmetest tuvastatud võsastunud põllumaa pindala on väiksem. See moodustas 84% digitaliseerimisel tuvastatud võsastunud põllumaast PRIA põllumassiivide korral, millele ei taotletud toetust, ning 99% põllumassiivide korral, millele taotleti toetust. Autor seletas erinevust võsastunud alade vahel asuvate väiksemõõtmeliste lagedate aladega, mis digitaliseerimisel jäid eristamata.

Eestis on käesoleva tööga sarnast meetodikat varem kasutanud Tamm jt (2014), kes hindasid objektipõhise pildianalüüsi ja tugivektormasina (*Support Vector Machine*) meetodite rakendatavust Eesti Topograafilise Andmekogu valitud maakattetüüpide (veekogud, mets ja põõsastikud, põllud ning looduslikud rohumaad) tuvastamiseks. Kasutati 4 lidarandmetest ning 3 ortofoto kanalitest arvutatud andmekihti. Kõikide maakattetüüpide keskmisena oli klassifitseerimistäpsus mõõdukas ( $K = 0,73$ ), parim täpsus saadi metsa ja põõsastike tuvastamisel ( $K = 0,85$ ).

## 2. Uurimisala ja andmed

### 2.1. Uurimisala

Uurimisala asub Eesti Põhikaardi 1 : 10 000 lehe number 54194 piires. Ala asub Põlva ja Võru maakonnas Lasva ja Orava valdade piires (joonis 1).



Joonis 1. Uurimisala paiknemine Eestis (vasakul) ja lähimate Kagu-Eesti valdade taustal (paremal).

Arvutusressursi kokkuhoidmiseks piirati uurimisala ulatus ühe 1 : 10 000 Põhikaardi lehega. Asukohavalikul lähtuti kolmest kriteeriumist.

1. Asukoht PRIA 2015. aasta pindalatoetuste kaugseirekontrollala sees. See tagab PRIA tavapärase kaugseiremetoodikaga kontrollitud ajakohaste võrdlusandmete olemasolu.
2. Asukoht Maa-ameti 2015. aasta kaugseireandmete (ortofotod ja aerolaserskaneerimine) kogumisalal. See võimaldab kasutada lähteandmetena ajakohaseid riiklikult toodetavaid kaugseireandmeid.
3. Eelnevale kahele tingimusele vastavas ruumis valiti kaardileht, millesse jäi võimalikult palju põllupiiride muutusi. Otsustati PRIA kontrollieelsete ja -järgsete põllumassiivide vahe visuaalse hindamise põhjal.

Uurimisala 25 km<sup>2</sup>-st 13,55 km<sup>2</sup> on PRIA andmetel põllumajandusmaa.

## 2.2. Andmed

### 2.2.1. ALS-andmed

Kasutati 2015. aastal Maa-ameti kogutud aerolaserskaneerimise andmete alusel arvutatud normaliseeritud maakatte kõrgusmudelit (*normalised Digital Surface Model* - nDSM). Andmed koguti 2400 m kõrguselt aerolaserskanneriga ALS50-II perioodil 10.05–01.06.2015 (Maa-amet, 2015c). Keskmise kõrguspunktide tihedus on algandmetes 0.45 p/m<sup>2</sup>. Normaliseeritud maakatte kõrgusmudeli saamiseks on maakatte kõrgusmudelist lahutatud maapinna absoluutkõrgus. Seega kajastab nDSM ainult maapinnast kõrgemate objektide suhtelist kõrgust maapinnast. Sisse on arvatud minimaalselt 2 m kõrgused objektid (Maa-amet, 2015d). Madalamate objektide väljajäämine on kooskõlas uurimistöö eesmärgiga, kuna roht- ja puittaimede eristamispiir on samuti umbes 2 m (Lang, 2013). Mudeli ruumiline lahutus on 1 m, kuid maksimaalselt 2,6-meetrise punktivahe tõttu üle-eestisel aerolaserskaneerimisel võib esineda ebatäpsusi väiksemate objektidega. Valmis nDSM-i kasutati, et hoida uurimistöö põhitähelepanu klassifitseerimis- ja segmenteerimisülesannetel ning leida täiendavat rakendust Maa-ameti arendatud toodetele.


### 2.2.2. Ortofotod

Kasutati aerokaameraga Leica ADS40-SH52 perioodil 10.05–01.06.2015 tehtud Maa-ameti valevärvi ortofotosid ruumilise lahutusega 25 cm ja radiomeetrilise lahutusega 8 bitti (Maa-amet, 2015e). Nii ortofotod kui ALS-andmed pärinevad samast ajast. Andmed on kogutud 2400 m kõrguselt.

Kasutatud ortofotod sisaldavad kolme kanalit: lähisinfra punane (NIR), roheline (G) ja punane (R). Valgustingimuste muutlikkuse mõju vähendamiseks arvutati ortofoto kanalitest indeksitel põhinevad uued andmekihid.

- Taimkatte normaliseeritud vaheindeks (*Normalised Difference Vegetation Index* (NDVI)).  $NDVI = \frac{NIR-R}{NIR+R}$  (Rouse jt, 1973)
- Vee normaliseeritud vaheindeks (*Normalised Difference Water Index* (NDWI)).  $NDWI = \frac{G-NIR}{G+NIR}$  (Richards, 2013)


Andmekihtide illustreerimiseks on esitatud väljavõtted hallskaalas NDVI-st (joonis 2, vasakul) ning hallskaalas NDWI-st (joonis 2, keskel). Võrdluseks on loomulikes värvides RGB ortofoto (joonis 2, paremal).



**Joonis 2.** Väljavõte hallskaalas esitatud NDVI (vasakul) ja NDWI (keskel) andmekihist. Tumedad toonid tähistavad madalaid väärtusi ja heledad kõrgeid. Võrdluseks loomulikes värvides RGB ortofoto (paremal).

### 2.2.3. Põldude vektorkiht

Kasutati kaht PRIA toodetud põllumassiivide vektorkihti. Seisuga 04.12.2015 tehtud põllumassiivide väljavõte on kasutusel kontrollieelse seisuna (joonis 3, vasakul). Seda objektipõhiste kaugseiremeetoditega uuendades on eesmärgiks saada võimalikult sarnane tulemus kontrollijärgse seisuga, milleks on 26.02.2016 tehtud põllumassiivide väljavõte (joonis 3, paremal). Selleks ajaks oli PRIA uurimisala põllumassiivide piirid kontrollitud ja uuendanud.



**Joonis 3. PRIA kontrollieelsed (vasakul) ja kontrollijärgsed (paremal) põllumassiivid. Taustaks loomulikes värvides ortofoto.**

#### **2.2.4. Maastikuelementide vektorkiht**

Põllumajandustoetuste määramise kord näeb ette, et toetusõigusliku põllumajandusmaa hulka arvatakse maastikuelemendid, mis kuuluvad maa heas põllumajandus- ja keskkonnaseisundis hoidmise nõuete alla ja on nõuetekohaselt deklareeritud (joonis 4) (Peepson jt, 2015). Selliseks maastikuelemendiks võib olla (Peepson jt, 2015):

- põllusaar
- metsasiil
- puude rida
- puude või põõsastega hekk
- eesvool ja kuivenduskraav
- kiviaed
- looduskaitsealune puu, kivi ja allikas
- muinsuskaitsealune kinnismälestis, matusepaik, muistne põld, lohukivi, kultusekoht, tee või sild
- pärandkultuuriobjektina kaardistatud mälestuskivi, pärimustega allikas, puu, kivisild, kivitruup, munakivitee või karjatanum



**Joonis 4. Toetusõigusliku põllumaa juurde kuuluvad maastikuelemendid. Taustaks loomulikes värvides ortofoto.**

Maastikuelemendid deklareerib maaomanik koostöös PRIA-ga. Toetusõiguslike maastikuelementidega on võsa piiritlemisel oluline arvestada, sest nad võivad olla väliselt võsaga sarnased, kuid kuuluvad põllumajandusmaa juurde.

### **3. Metoodika**

Võsastumise tõttu muutunud põllupiiride leidmine taandub võimalikult täpsele võsastunud alade piiritlemisele. Võsastunud alad leiti kahel viisil. Esiteks ainult nDSM-i andmete alusel ning teiseks nDSM-i ja optiliste kaugseireandmete kombinatsioonis. Uute piiridega põllud saadi mõlemal juhul, lahutades kontrollieelse seisuga põllumassiividest erinevate lähteandmetega leitud võsa. Seega ei kajasta käesoleva töö metoodikaga leitud põllupiirid muudel põhjustel muutunud piire, sealhulgas ka põllumaa kasvamist. Kummalgi meetodil leitud põllupiire võrreldi tegeliku seisuga, milleks loeti PRIA kontrollitud põllumassiivide vektorkihti 2015. aasta kohta.

Optiliste andmete ja nDSM-i alusel võsa leidmisel kasutati objektipõhise pildianalüüsi tarkvara eCognition Developer 9.0. Kummalgi viisil leitud võsaproducti töötlusprotsess on peaaegu identne, kui välja arvata kasutatavad andmekihid ning mõned sellest tulenevad erisused. Detailse ülevaate arvutuseeskirjadest annavad lisad 1 ja 2, mis sisaldavad mõlema töötlusprotsessi dokumentatsiooni. Kõige üldisemalt jaguneb töötlusprotsess kolmeks:

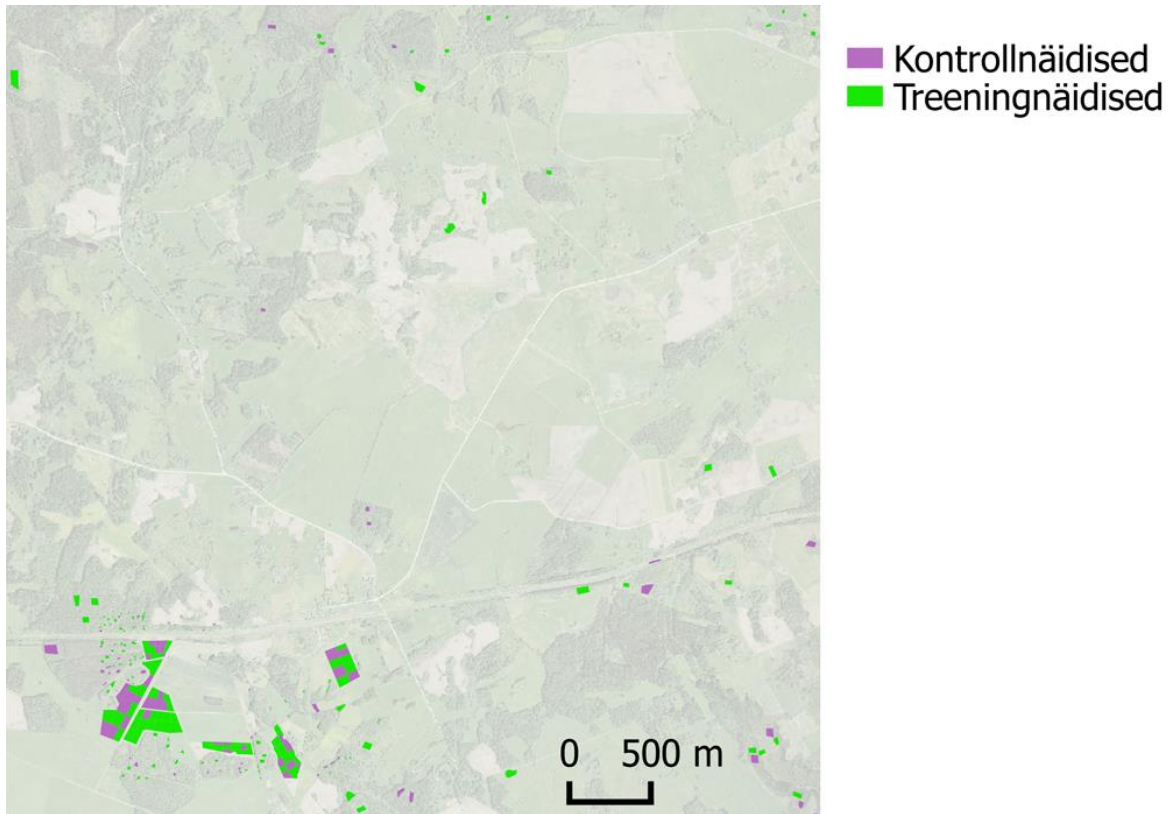
1. Tugivektormasina treenimine näidiste alusel.
2. Segmenteerimine ja eelnevalt treenitud tugivektormasina järgi klassifitseerimine.
3. Tulemuse ettevalmistamine ekspordiks ning eksportimine.

Alljärgnevad peatükid tutvustavad neid kolme etappi lähemalt.

#### **3.1. Tugivektormasina treenimine**

Klassifitseerimiseks kasutati masinõppel põhinevat tugivektormasina meetodit. Tugivektormasina kasutavad klassifitseerimiseks juba klassifitseeritud õpetusandmeid (Remm jt, 2012). Tunnusruumis otsib tugivektormasin erinevatesse klassidesse kuuluvate näidiste vahel sellist eralduspinda, mis asuks kummagi klassi esindajatest võimalikult kaugel. Uued andmepunktid klassifitseeritakse leitud eralduspinna järgi.

Tugivektormasinat treeniti 200 näidisega, mis asusid uurimisalal. 200 treeningnäidist valiti juhuslikult näidiste üldhulgast, kus oli 300 näidist (joonis 5). Ülejäänud 100 näidist kasutati hiljem täpsushinnangu leidmisel. Treeningnäidised olid jagatud kahte klassi, Võsa ja Põld, kummaski 100 näidist.



**Joonis 5.** Kontroll- ja treeningnäidiste paiknemine uurimisalal. Taustaks vähendatud kontrastsusega loomulikes värvides ortofoto.

Tugivektormasina treenimiseks kasutatud tunnusteks olid andmekihtide keskmised ja standardhälbed, mis arvutati näidiste ruumikujusid arvestades. Standardhälve kirjeldab variatsiooni objektide sees ning on tekstuuri iseloomustava näitajana sageli kasutatud (Malinverni jt, 2011; Hellesen & Matikainen, 2013; Tamm jt, 2014). Tabel 1 annab ülevaate kasutatud andmekihtidest ja tunnustest vastavalt lähteandmete komplektile. Tunnused koguti kõigi treeningnäidiste kohta.

**Tabel 1.** Tugivektormasina treenimiseks kasutatud tunnused mõlemas võsaproductis


Võsaproduct nDSM-ist		Võsaproduct nDSM-ist ja optilistest andmetest	
Keskmine	Standardhälve	Keskmine	Standardhälve
nDSM	nDSM	nDSM	nDSM
		NDVI	NDVI
		NDWI	NDWI

### 3.2. Segmenteerimine ja klassifitseerimine

Segmenteeriti eCognition Developer 9.0 algoritmiga *multiresolution segmentation*, mida tutvustati teooria peatükis. Valiti järgmised parameetrite väärtused:

- ainult nDSM-il põhinev võsaproduct: skaala = 30, kuju = 0,1, kompaktsus = 0,5; andmekihtide kaalud – ainult nDSM
- nDSM-il ja optilistel andmetel põhinev võsaproduct: skaala = 60, kuju 0,1, kompaktsus = 0,5; andmekihtide kaalud – nDSM = 3, NDVI = 1, NDWI = 1

nDSM-il ja optilistel andmetel põhineva võsaproducti korral valiti kõrgem skaala väärtus, sest optiliste andmete kõrgem resolutsioon ja heterogeensus põhjustaks muidu palju väiksemad segmendid. Kuju ja kompaktsuse korral katsetati erinevaid väärtusi, kuid otsustati vaikeväärtuste kasuks, sest võsa võib olla varieeruva kujuga. Kuju ja kompaktsuse vaikeväärtusi kasutasid segmenteerimisel edukalt ka Yang jt (2015). Segmenteerimise tulemust näitlikustab joonis 6.



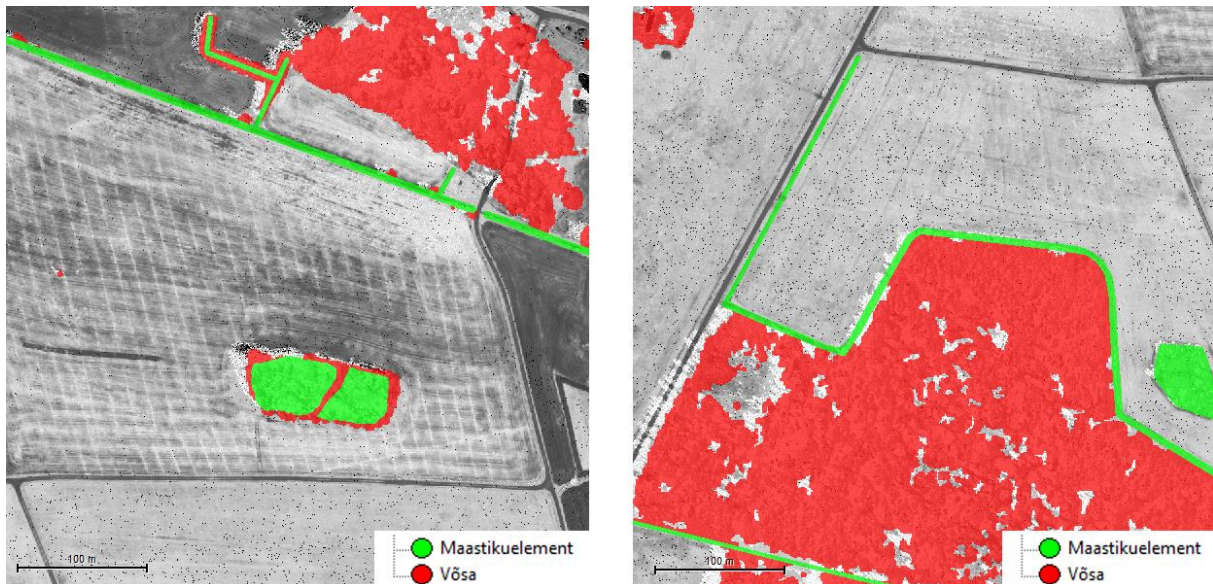
Joonis 6. Väljavõte segmenteerimisest, Taustaks NDVI andmekiht.

MRS-i tulemusele on iseloomulik, et osa segmente on ainult ühe kuni mõneteist piksli suurus. Selliste segmentide klassifitseerimine tugivektormasinaga on probleemne, sageli jäävad nad üldse klassifitseerimata. Esialgse segmenteerimise parandamiseks liideti segmendiga naabersegment, kui see oli väiksem kui 100 piksli suurune.

Seejärel klassifitseeriti saadud segmendid eelnevalt treenitud tugivektormasinaga. Klassifitseerimist täpsustati PRIA maastikuelementide andmekihiga. Maastikuelementide

ruumikuju pärineb kas Maa-ametist (loodus- ja muinsuskaitsealused objektid ja pärandkultuuriobjektid) või on deklareeritud maaomaniku ja PRIA koostöös. Kuna nende ruumikuju on vähemalt ühe korra juba kontrollitud, siis eeldati, et maastikuelementide ruumikuju on täpne ja need võeti muutmata kujul üle.

Maastikuelementidega piirnev võsa nõudis eraldi lähenemist, sest näiteks põllusaare ümber võib esialgsest klassifitseerimisest jääda kitsas võsariba, mis tegelikult kuulub klassi Maastikuelement juurde (joonis 7, vasakul). Teisalt võib maastikuelemendina arvel olev puude rida või kraav piirneda suurema puittaimedega kaetud alaga ja siis tuleb puuderea või kraavi kõrval asuv ala jätta klassi „Võsa“ (joonis 7, paremal). Tänu naabrussuhete arvestamisele on objektipõhine pildianalüüs selliste probleemide lahendamiseks sobilik.



**Joonis 7. Maastikuelemendid ja võsa pärast esialgset klassifitseerimist. Põllusaarte ümber tuleb võsa klassifikatsioon eemaldada (vasakul), aga kraaviga külgneva suurema võsastunud ala klassifikatsioon säilitada (paremal).**

Detailne eeskiri maastikuelementidega piirneva võsaga tegelemiseks on lisades 1 ja 2, siinkohal on selgitatud üldist loogikat:

1. Alguses esineb ainult kolm klassi: Võsa, Maastikuelement ja Klassifitseerimata. Viimane klass sisaldab kõiki muid klasse, mis ei kuulu esimese kahe alla.
2. Klassi Võsa kuuluvad segmendid, millel on klassi Maastikuelement kuuluv naaber, klassifitseeritakse ajutiselt klassi Võsa Maastikuelemendi Kõrval.
3. Klassi Võsa kuuluvad segmendid, millel on klassi Võsa Maastikuelemendi Kõrval kuuluv naaber, aga klassi Võsa kuuluvat naabrit ei ole, klassifitseeritakse samuti klassi Võsa Maastikuelemendi Kõrval. Sellega saadakse kätte väikesed alad, mis ulatuvad

üle maastikuelemendi servade, aga suured jäävad puutumata, sest neil on klassi Võsa kuuluvaid naabreid.

4. Klassi Võsa Maastikuelemendi Kõrval kuuluvad segmendid, millel on Klassifitseerimata naaber, aga klassi Võsa kuuluvat naabrit ei ole, liigitatakse klassi Klassifitseerimata. See lahendab eelmises punktis esiletoodud alad.
5. Klassi Võsa Maastikuelemendi Kõrval kuuluvad segmendid, millel ei ole Klassifitseerimata naabrit, aga klassi Võsa kuuluv naaber on, liigitatakse klassi Võsa. See lahendab maastikuelemendi ja suurema võsaala vahel asuvad suletud alad.
6. Klassi Võsa Maastikuelemendi Kõrval kuuluvad segmendid, millel on klassiga Võsa pikem piir kui klassiga Maastikuelement, liigitatakse klassi Võsa. See lahendab alad, millel on piir nii klassiga Klassifitseerimata kui ka klassiga Maastikuelement.
7. Klassi Võsa Maastikuelemendi Kõrval allesjäänud segmendid liigitatakse klassi Klassifitseerimata.

### **3.3. Eksportimine**

Klassifitseerimistulemused eksporditi, et neid oleks võimalik edaspidi kasutada teistes GIS-tarkvarades ja kombineerida PRIA põllumassiivide andmekihiga.

Ekspordiks ettevalmistamine hõlmab peamiselt tegevusi, mis generaliseerivad lõpptulemust. Segmendid liideti klasside kaupa kokku ja klasside piirjooni siluti  $5 \times 5$  piksli suuruse aknaga. Piirjooni siluti, et viia võsapiirid paremasse vastavusse põllupiiride mõõtkavatäpsusega, parandada loetavust ning muuta piirjooned loomulikumaks. Silumiseks kasutati eCognition Developer 9.0 algoritmi *Pixel-Based Object Resizing* (Trimble, 2014).

Seejärel eemaldati objektid, mis on väiksema pindalaga kui PRIA poolt minimaalselt põllumaal eristatav pind (0,01 ha). Viimaks salvestati tulemus vektorvormingus.

### **3.4. Klassifitseerimis- ja asukohatäpsuse hindamine**

Klassifitseerimistäpsust hinnati 100 kontrollnäidise abil, mis olid analoogselt treeningnäidistele jagatud kahe klassi vahel („Võsa“ ja „Põld“), kummaski 50 näidist. Kontrollnäidiste kohta arvutati veamaatriksid, Kapa (K) koefitsient, kasutaja-, tegija- ja kogutäpsus (Congalton & Green, 2009). Kasutati tarkvara eCognition Developer 9.0.

Kahe klassifitseerimistulemuse erinevust võrreldi vastavate veamaatriksite põhjal arvutatud Z-statistikuga (Congalton & Green, 2009).

nDSM-st ning nDSM-st ja optilistest andmetest tuletatud põllupiiride asukohatäpsust hinnati kolmel meetodil. Kõigil juhtudel kasutati tarkvara ArcGIS 10.2.

Kontrollitavate joonte käänupunktide kauguste sagedusjaotused etalonist leiti ArcGIS-i tööriistadega *Feature Vertices to Points* ning *Near*. Tööriista *Feature Vertices to Points* abil eraldati erinevatest lähteandmete komplektidest arvutatud põllupiiride käänupunktid. Tööriistaga *Near* arvutati vähim kaugus igast käänupunktist PRIA kontrollitud põllupiirini. Kaugused salvestati käänupunktide kihi atribuuttabelisse. Ühiseks loeti käänupunkt, mille kaugus etalonist oli 0. Selle meetodi puuduseks on sõltuvus joont moodustavate käänupunktide paiknemise tihedusest.

Kontrollitavate põllupiiride keskmine kaugus PRIA kontrollitud põllupiiridest leiti joonte keskmise kauguse meetodil (*mean distance method*) (Ariza-Lopez & Mozas-Calvache, 2012). Kontrollitava joone X ja võrdluse alusena kasutatava joone Q keskmine kaugus D leitakse valemist

$$D(Q, X) = \frac{\text{Pindala}(Q, X)}{\text{Pikkus}(X)} \quad (6),$$

kus pindala on joonte Q ja X vahele jääva ala pindala.

Etalonkihiga kattuva või sellest kuni kindlal kaugusel asuva arvutusliku põllupiiri osakaal leiti Goodchildi ja Hunteri (1997) tutvustatud meetodil. Seda on nimetatud ka üksiku puhvri ülekatte meetodiks (*single buffer overlay method*) (Ariza-Lopez & Mozas-Calvache, 2012). Selleks tekitatakse referentsina kasutatava joone ümber erineva laiusega puhvrid ja leitakse, kui suur osa kontrollitavast joone pikkusest jääb puhvri sisse.

## 4. Tulemused ja arutelu

### 4.1. Kirjeldav analüüs

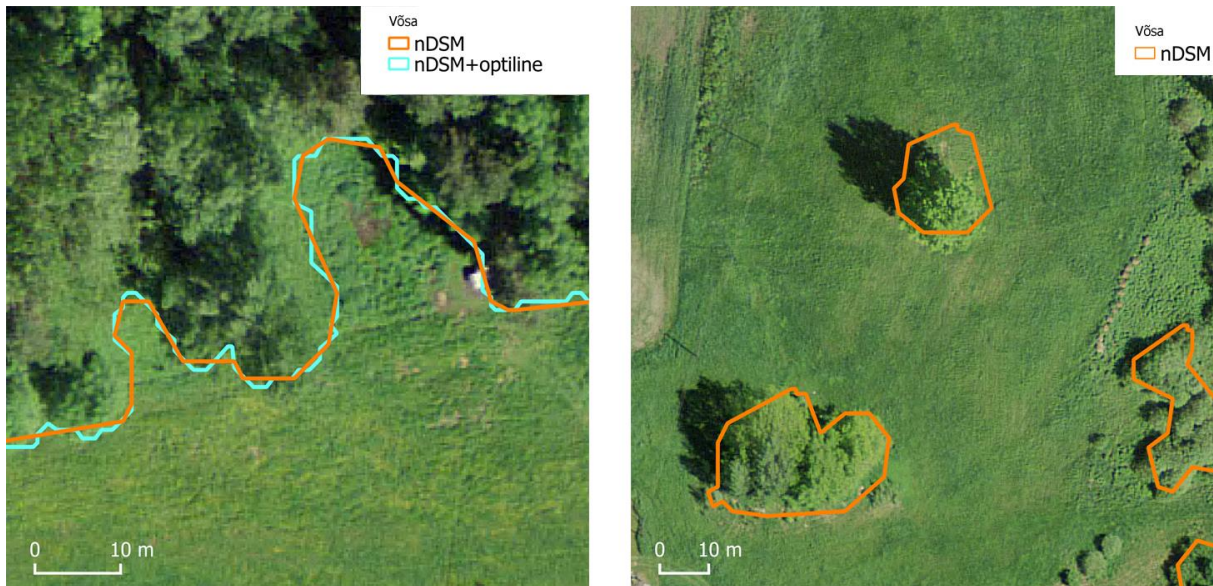
Suur osa põllupiiridest on püsinud muutumatuna, sest tegelikke muutusi põldude ulatuses kahe kontrolli vahel ei toimu väga palju. Seetõttu on üldisel vaatlusel kõik põldude kihid sarnased. Kohtades, kus muutused on toimunud, ei ole alati põhjuseks võsastumine, vaid näiteks põllumaa registrist eemaldamine. Selliseid muutusi ei analüüsitud, kuna käesoleva töö fookuses on ainult võsastumise tõttu toimunud muutused.

Kahel viisil leitud võsaproducti kogupindala erineb ainult 3,2 ha võrra (tabel 2). Samas iseloomustab nDSM-ist ja optilistest andmetest leitud võsakihti suurem fragmenteeritus. Võrreldes ainult nDSM-ist leitud võsakihiga koosneb see palju enamatest lahustükkidest, vastavalt 1344 ja 1044, mille keskmine pindala on väiksem, vastavalt 0,56 ja 0,71 ha.

**Tabel 2. Kirjeldavad statistikud nDSM-ist ning nDSM-ist ja optilistest andmetest arvatud võsaproductide ning põllupiiride kohta.**

<b>Võsa</b>		<b>nDSM</b>	<b>nDSM ja optiline</b>	
Kogupindala, ha		744,1	747,3	
Keskmine pindala, ha		0,71	0,56	
Koguümberrõõm, km		382,12	495,64	
Elementide arv		1044	1344	
<b>Põld</b>	<b>PRIA kontrollieelne</b>	<b>nDSM</b>	<b>nDSM ja optiline</b>	<b>PRIA kontrollijärgne</b>
Kogupindala, ha	1364,8	1350,6	1350,0	1355,2
Koguümberrõõm, km	352,78	361,02	370,84	352,02
Elementide arv	263	262	262	272

Varasemate põllupiiride ruumikujudest võsaproductide lahutamisel saadud põllukihid on samuti pindalalt väga sarnased (tabel 2). Siingi iseloomustab nDSM-ist ja optilistest andmetest leitud piire suurem keerukus (joonis 8, vasakul). Võrdväärse pindala ning põldude arvu juures on kihi kõikide elementide summaarne ümbermõõt 9,82 km pikem. Joonte suurem keerukus optiliste andmete kasutamisel võib olla põhjustatud optiliste andmete kõrgemast ruumilisest lahutusest. Kasutatud ortofotode piksli suurus maapinnal oli 0,25 m ja nDSM-il 1 m.



**Joonis 8.** Vasakul: ainult nDSM-ist arvatud võsaproducti piirid ei ole nii keerukad kui nDSM-ist ja optilistest andmetest arvatud võsaproducti piirid. Paremalt: aerolaserskaneerimise ning ortofotode kujutise tekitamise geometria erinevustest tulenev viga põhjapoolse puu juures.

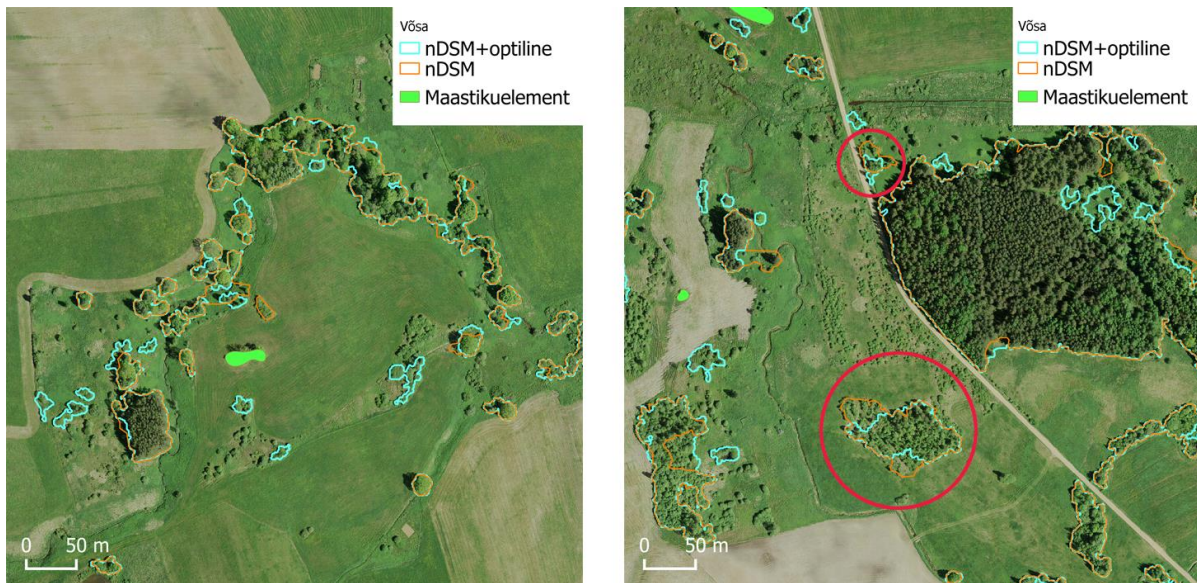
Joonisel 8, paremal on näha, et nDSM-i järgi tõmmatud piir põhjapoolse, kõrgema puu kirdeküljel ei lange ortofotol paistvaga hästi kokku, kuid lõunapoolse, madalama puudegrupi piirid ühtivad paremini. Erinevus on ilmselt põhjustatud andmeallikate erinevast geometriast. Chen jt (2011) leidsid, et aerolaserskaneerimise ja optiliste andmete kooskasutus võib põhjustada probleeme objektidega, mis on väiksemad kui 0,04 ha. Probleemid väljenduvad selles, et samas ruumipunktis võib aerolaserskaneerimise järgi olla kõrge taimkate, kuid ortofoto järgi mitte, või vastupidi. See on põhjustatud aerofoto plaanilisest geometriast, mida ortorektifitseerimisel venitatakse. Enim on mõjutatud suure kõrguste vahega punktide plaaniline asukoht, näiteks maapinnast kõrgel asuvad objektid (puude ladvad) või tugevalt reljeefse maastikuga alad. Seevastu lidar põhineb otseselt kauguste mõõtmisel, mistõttu võib selle horisontaalset täpsust võsa piiride määramisel pidada paremaks.

Siiski esineb aerolaserskaneerimise ja ortofoto kujutiste moodustamise geomeetria erinevusest põhjustatud andmete ruumilist sobimatust vähe, kuigi väikseimaks eristatavaks objektiks oli 0,01 ha. Moonutuste madalat taset saab seletada uurimisala suhteliselt tasase reljeefiga ning võsa piiride omadustega. Sellised piirid ei too efekti teravalt esile, kuna võsa ja lageda ala üleminekul ei kasva kõige kõrgemad puud.

Tulemusi mõjutab kindlasti aerolaserskaneerimise aeg, mis käesolevas töös kasutatud andmete korral toimus vahemikus 10.05–01.06. Võib arvata, et eriti perioodi alguses ei olnud kõikide puuliikide lehestik veel täielikult välja arenenud. Lehestiku tihedusest oleneb, kui suur osa lidari väljasaadetud impulssidest hajub tagasi maapinnalt ja kui suur osa puude võradest. Sellest tulenevalt on kõige parem andmete kogumise aeg kesksuvi.

Enamasti on ainult nDSM-ist ning DSM-ist ja optilistest andmetest arvatud võsaproductid väga sarnased – eristuvad samad võsaalad ning piiride omavaheline kaugus ei ületa paari meetrit. Erinevuseid analüüsides võib öelda, et DSM-ist ja optilistest andmetest arvatud piirid on üldiselt täpsemad. Ainult DSM-ist arvatud võsaproducti suurem ebatäpsus väljendub selles, et sageli esinevad aerofoto järgi lahus olevad võsaalad agregeeritult. See tähendab, et ka võsa vahel asuvad muu maakattetüübiga alad võivad olla liigitatud võsaks. DSM-ist ja optilistest andmetest arvatud võsaproduct järgib võsa piiri täpsemalt ja vahed ning tühimikud joonistuvad paremini välja.


Suurimad erinevused kummagi võsaproducti vahel esinevad madala ja väikeste laikudena paikneva võsa tuvastamises. Sellised on näiteks noore võsa või põõsastikega kaetud alad. Nende klassifitseerimine võsaks ei ole järjepidev. Visuaalsel hinnangul osutub üldiselt paremaks DSM-ist ja optilistest andmetest arvatud võsaproduct (joonis 9, vasakul), kuigi leidub üksikuid erandeid (joonis 9, paremal).



**Joonis 9.** Vasakul: üldiselt eristab nDSM-ist ja optilistest andmetest arvatud võsaproduct madalat, laiguti esinevat võsa paremini. Paremalt: leidub üksikuid kohti, kus madala võsaga tuleb paremini toime ainult nDSM-ist arvatud võsaproduct (märgitud punase ringjoonega). Osa madalamast ja hõredamast võsast jääb mõlemal juhul klassifitseerimata.

Ainult nDSM-ist arvatud võsaproducti puhul on madala võsa tuvastamise probleem ilmne, sest kasutatud Maa-ameti nDSM sisaldab maapinnast minimaalselt 2 m kõrguseid objekte. nDSM-ist ja optilistest andmetest leitud võsaproductile on iseloomulikum täpsem piiride ja tühimike järgimine, samas ainult nDSM-ist arvatud võsaproduct liidab alad sagedamini kokku. Kummagi meetodi ühise joonena saab välja tuua üldiselt konservatiivse klassifitseerimistulemuse. Pigem jääb piiripealne situatsioon võsaks klassifitseerimata, selle asemel, et klassifitseeritakse põld võsaks.

Esineb kohti, kus arvutuslikult leitud võsakihtidest tuletatud põllupiirid on täpsemad kui PRIA kontrollitud piirid (joonis 10). Arvutuslike võsakihtide abil on võimalik leida kontrollis märkamata jäänud võsa põllumaa sees. Siiski ei saa olla täiesti kindel, et sellised alad arvutuslike võsakihtidega kindlasti välja tulevad.



Joonis 10. PRIA kontrollitud põllupiirides leidub võsastumisest muutmata jäänud piire, mis arvutuslike võsakihtide abil üles leiti.

## 4.2. Võsaproductide klassifitseerimistäpsus

Referentsandmete järgi hinnatud võsa klassifitseerimistäpsus on väga kõrge. Kapa koefitsient on kummalgi juhul vähemalt 0,91 (tabel 3 ja tabel 4). Tabelites olevad loendusarvud ei ole näidiste, vaid segmenteeritud näidiste kohta. Kasutajatäpsus ehk tõenäosus, et võsaks klassifitseeritud alal on ka tegelikult võsa, on vähemalt 0,98. Tegijatäpsus ehk tegelikkuses esinev võsa on õigesti võsaks klassifitseeritud tõenäosusega 0,96.

Tabel 3. nDSM võsaproducti veamaatriks ja täpsushinnangud kontrollnäidiste alusel. Ridades on klassifitseerimistulemused ja veergudes võrdlusandmed.

	Võsa	Põld	Kokku	Kasutajatäpsus	K
Võsa	146	0	146	1	1
Põld	6	40	46	0,87	0,84
Kokku	152	40	192		0,91
Tegijatäpsus	0,96	1		<b>Kogutäpsus 0,97</b>	

**Tabel 4. nDSM ja optiliste andmete võsaproducti veemaatriks ja täpsushinnangud kontrollnäidiste alusel. Ridades on klassifitseerimistulemused ja veergudes võrdlusandmed.**

	<b>Võsa</b>	<b>Põld</b>	<b>Kokku</b>	<b>Kasutajatäpsus</b>	<b>K</b>
<b>Võsa</b>	257	4	261	0,98	0,95
<b>Põld</b>	10	114	124	0,92	0,88
<b>Kokku</b>	267	118	385		0,92
<b>Tegijatäpsus</b>	0,96	0,97		<b>Kogutäpsus 0,96</b>	

ALS-andmestik võimaldab võsa muudest maakattetüüpidest kõrguse alusel selgelt eristada, seega on kõrge täpsushinnang ootuspärane. Tuleb silmas pidada, et tegemist on tõenäosusliku täpsushinnanguga, mis oleneb kontrollnäidiste kvaliteedist. Seega ei saa järeldada, et ainult nDSM-ist arvatud võsaproductis, mille kasutajatäpsus võsa jaoks on 1, on absoluutselt kõik võsaks klassifitseeritud alad tegelikkuses võsaga kaetud.

Kahe veemaatriksi erinevus ei ole Z-statistiku järgi statistiliselt oluline.  $Z = 0,13$ , 95% usaldusnivoo juures saaks nullhüpooteesi kõrvale heita, kui  $Z \geq 1,96$ . Kahel viisil leitud klassifitseerimistulemust ei saa statistiliselt erinevaks pidada.

### **4.3. Põllupiiride joontel põhinevad võrdlused etaloniga**

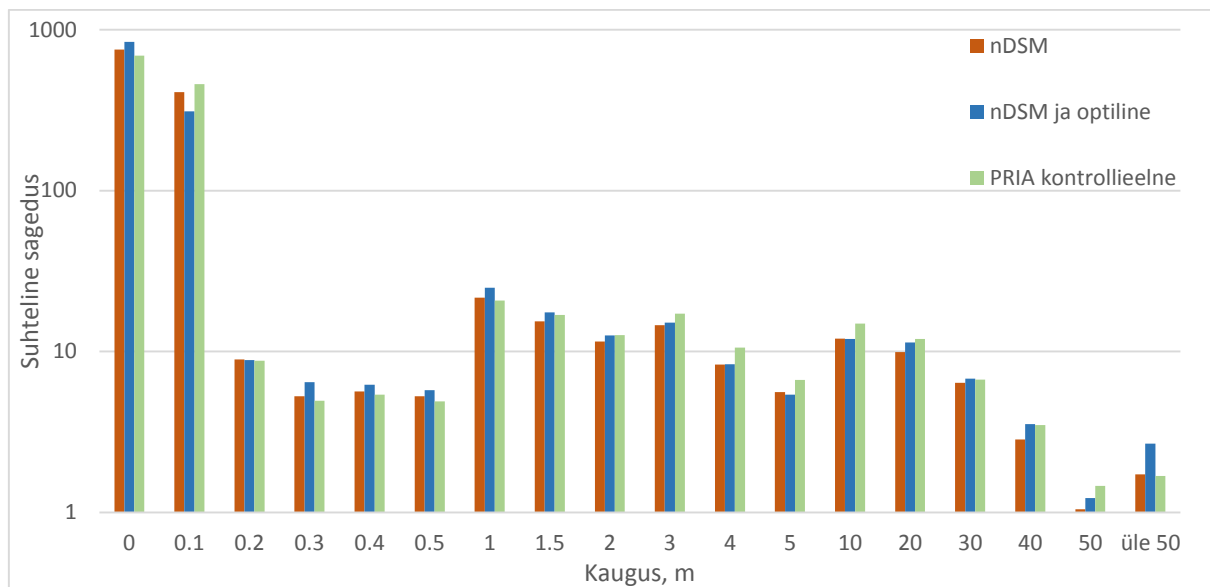
Keskmine kaugus etalonina kasutatud PRIA kontrollijärgsetest põllupiiridest leiti lisaks nDSM-st ning nDSM-ist ja optilistest andmetest arvatud põllupiiridele võrdluseks ka PRIA kontrollieelsetele põllupiiridele (tabel 5). Tuleb rõhutada, et kõik muutused ei ole toimunud ainult võsastumise tõttu. See vähendab arvutuslike põllupiiride täpsust, mis arvestavad ainult võsastumist. Kummagi lähteandmete komplektiga leitud võsaproductidest tuletatud põllupiirid on keskmiselt 69 cm kaugusel PRIA kontrollitud põllumassiivide piiridest. PRIA kontrollieelsed põllupiirid on arvutuslikest põllupiiridest etalonile keskmiselt lähemal. Sellest hoolimata jagavad arvutuslikud põllupiirid etaloniga rohkem ühiseid käänupunkte.

**Tabel 5. nDSM-ist ning nDSM-ist ja optilistest andmetest arvatud põllupiiride ning PRIA kontrollieelsete põllupiiride kaugus PRIA kontrollijärgsetest põllupiiridest.**

	<b>Põllupiir nDSM-ist</b>	<b>Põllupiir nDSM-ist ja optilistest andmetest</b>	<b>PRIA kontrollieelne</b>
Keskmine kaugus etalonist, cm	69	69	48
Ühiseid käänupunkte etaloniga, %	58,1	64,6	53,2

Mõlema meetodiga leitud põllupiiride suurim kaugus PRIA kontrollitud põllupiirist oli umbes 150 meetrit, kuid sel juhul ei olnud tegemist võsastumisega, vaid põllu registrist kustutamisega.

Erinevatel meetoditel leitud põllupiiride käänupunktide kauguse sagedusjaotuse võrdlusel kontrollijärgse seisuga tuleb välja, et kõige suurem osa varieeruvusest on väga väiksemõõtmeline, vaid kuni 0,1 m (joonis 11). Sellist piiride muutumist ei saa pidada võsastumisest või muust välisest tegurist põhjustatuks. Pigem on väiksemõõtmeline varieeruvus seletatav juhusliku veaga põllupiiride märkimisel, sest sellise skaalaga muutlikkus on kõige suurem PRIA kontrollieelse ja -järgse põllukihi vahel, kus see võiks teoreetiliselt olla null.



**Joonis 11. Kauguste sagedusjaotus PRIA kontrollijärgsetest põllupiiridest: nDSM-ist ja optilistest andmetest arvatud põllupiirid, ainult nDSM-ist arvatud põllupiirid ning võrdluseks PRIA kontrollieelsed põllupiirid. Kõik suhtelised sagedused korrutatud 1300-ga, et vähim suhteline sagedus oleks suurem kui 1, mis tagab logaritmskaalas Y-telje positiivsed väärtused.**

Joonte kokkulangevused mõlemast lähteandmete komplektist leitud põllupiiride korral on väga sarnased (tabel 6). Mõlemal juhul asub vähemalt 95% piirist etalonpiirile lähemal kui 5 m ja 79% lähemal kui 1 m. Täielikult kattub etaloniga 14–14,5% piirist. Marginaalselt suurem joonte kokkulangevus on nDSM-ist arvatud põllupiiril.

**Tabel 6. Osakaal (%) nDSM-ist ning nDSM-ist ja optilistest andmetest arvatud põllupiiride pikkusest, mis kattub PRIA kontrollitud põllupiiridega või asub sellele lähemal kui 0,25, 0,5, 1, 1,5, 2 või 5 m.**

Kaugus, m	Põllupiir nDSM-ist	Põllupiir nDSM-ist ja optilistest andmetest
0	14,49	14,04
0.25	71,45	69,26
0.5	74,73	72,73
1	80,32	78,63
1.5	84,70	83,31
2	88,07	86,96
5	96,00	95,59

## Kokkuvõte

Töö eesmärgiks oli töötada välja objektipõhine meetodika võsastumise tõttu muutunud põllupiiride leidmiseks ning seejärel kahest erinevast andmestikust saadud piire omavahel võrrelda. Terminit „võsa“ kasutati igasuguse põllumajandustegevust takistava puittaimestiku tähenduses. Töötati välja objektipõhine võsa piiritlemise meetodika, mille lähteandmetena kasutati esiteks ainult nDSM-i ning teiseks nDSM-i koos optiliste kaugseireandmetega. Optiliste andmetena kasutati Maa-ameti kolmekanalilisest valemvärvi (NIR, G, R) ortofotost arvutatud NDVI ja NDWI andmekihte resolutsiooniga 0,25 m. Mõlema meetodi puhul kasutati Maa-ameti arvutatud nDSM-i resolutsiooniga 1 m. Uurimisalaks valiti Eesti Põhikaardi 1 : 10 000 kaardilehele nr 54194 jääv ala.

Võsa piiritlemiseks kasutati objektipõhise pildianalüüsi meetodit. See erineb pikslipõhisest selle poolest, et pildi segmenteerimisega moodustatakse võimalikult tegelike objektide ruumikujusid järgivad segmendid ehk pildiobjektid. Kuna edasi on võimalik tugineda üksikute pikslite asemel pildiobjektidele, saab nende kirjeldamiseks ja klassifitseerimiseks kasutada uusi kasulikke näitajaid, nagu naabrussuhted või tekstuur.

Klassifitseerimisel kasutati masinõppel põhinevat tugivektormasinat. Tugivektormasina treenimiseks koguti 200 treeningnäidiselt seletavate tunnustena andmekihtide keskmised ja standardhälbed. Klassifitseerimistäpsust hinnati 100 kontrollnäidisega.

Ainult nDSM-ist tuvastatud võsa pindala oli 744,1 ha, nDSM-st koos optiliste andmetega aga 747,3 ha. Sarnane kogupindala jagunes nDSM-i ja optiliste andmete kooskasutamisel rohkemate võsa lahustükkide vahel, mille keskmine pindala oli 0,56 ha, kuid ainult nDSM-i kasutamisel 0,71 ha.

Ainult nDSM-ist leitud võsaproducti ning nDSM-ist ja optilistest andmetest leitud võsaproducti klassifitseerimistäpsus ei erinenud oluliselt. Kummalgi juhul saadi kõrgeid hinnanguid kogutäpsusele (0,96–0,97) ning Kapa koefitsiendile (0,91–0,92). Vastavatest võsaproductidest tuletatud põllupiirid olid samuti sarnased. Kumbki arvutuslik põllupiir asus keskmiselt 0,69 m kaugusel etalonina kasutatud PRIA kontrollijärgsest põllupiirist. Vähemalt 95% arvutuslike põllupiiride pikkusest asus etalonile lähemal kui 5 m. Lähemal kui 1 m asus 80% (nDSM-ist tuletatud) või 78% (nDSM-ist ja optilistest andmetest tuletatud) piirist.

Erinevused ilmsid visuaalsel analüüsil. nDSM-ist ja optilistest andmetest arvatud võsaproduktile (ja sellest tuletatud põllupiirile) oli iseloomulikum keerulisem piir, mis järgis paremini puudevahelisi tühimikke ega kippunud lähestikku asuvaid võsa lahustükke agregeerima. Samuti oli see efektiivsem madala ja noore võsa ning põõsastike tuvastamisel, kuna Maa-ameti nDSM-i minimaalseks kõrguspiiranguks on 2 m.

Kuigi statistilist erinevust kahe lähteandmete komplektiga saadud tulemuste vahel ei leitud, on nDSM-ist ja optilistest andmetest tuletatud põllupiirid erinevuste visuaalsel analüüsil kvaliteetsemad. Nende lähteandmete puuduseks on suurem arvutusmahukus, sest võrreldes ainult nDSM-st leitud põllupiiridega kasutatakse täiendavalt kaht andmekihti, mille lineaarne resolutsioon on 4 korda kõrgem.

# Object-based mapping of secondary forest succession on agricultural land with remote sensing data

Villem Voormansik

## Summary

Agricultural land makes up about 22,4% of the area of Estonia (Statistikaamet, 2016). On the national level, the Estonian Agricultural Registers and Information Board has the duties to manage the information concerning agricultural land. This also involves keeping track of the spatial changes of individual pieces of arable land. It has great potential to study ways that help to automate the task which has so far been dealt with mostly manually.

Secondary forest succession is one of the driving factors causing changes to the borders of agricultural land (Hellesen & Matikainen, 2013; Tamm, 2014; Kolečka jt, 2015). Taking this into account, this paper focuses on using object-based remote sensing techniques for mapping the changes in arable land that are caused by the increase in woody plant cover. The aim of the study is to develop a method for classifying woody plant cover and to compare its results using two different data sets. The data sets used are (1) normalised digital surface model (nDSM) with 1 m resolution and (2) nDSM with normalised difference vegetation index (NDVI) and normalised difference water index (NDWI) data layers. NDVI and NDWI were calculated from images taken with Leica ADS40-SH52 and had 0,25 m resolution. Instead of directly using the spectral bands, indices were chosen to reduce the effect of variability in illumination.

The study area is located in South-Eastern Estonia and follows the borders of Estonian Basic Map sheet nr 54194. The area is 5 × 5 km.

The difference between pixel-based and object-based image analysis, implemented in this study, lies primarily in segmenting the image before classifying. Segments or image objects are delineated following along the shapes of real objects as close as possible. Since object-based image analysis provides the possibility to rely on segments instead of pixels, useful new features like neighbouring relations or texture can be used to process or classify the image.

Classification was carried out with support vector machine (SVM). 200 training samples were used to train the SVM. Every data layer's mean and standard deviation values were collected as explaining features. Later, the classification accuracy was assessed using 100 test samples.

The difference between classification accuracy of the two results was not significant. Both achieved high overall estimated accuracy (0,96-0,97) and Kappa (0,91-0,92). The average distance between the reference arable land border and the derived borders was 0,69 m in both cases. At least 95% of the length of the borders was closer than 5 m to the reference border and around 80% was closer than 1 m.

Visual analysis revealed some differences between the products. Arable land borders derived using nDSM with optical data tended to be more complex and were more sensitive to small gaps between separate groups of shrubs and trees. The borders derived from nDSM alone often had such gaps aggregated with nearby woody plants. The nDSM product was not as effective with younger and lower brushwood as well, since its minimal relative height was restricted to 2 m.

Although statistically very similar, visual analysis suggested the borders derived from nDSM and optical data have better quality. In this case, the drawback is the need for more computational power since it adds two optical data layers which have 4 times the linear resolution of the nDSM used.

## **Tänuavaldused**

Suur tänu minu juhendajale Tanel Tammele mitmekülgse abi ja nõuannete ning pühendatud aja eest. Samuti tänan kaasjuhendajat Martin Jüssi, kes aitas seada probleemi fookuse ja korraldada koostööd PRIA-ga. Soovin tänada ka Maa-ametit kaugseireandmete ning PRIA-t põllumassiivide andmete ja konsulteerimise eest.

## Kasutatud kirjandus

- Ariza-Lopez, F. J. & Mozas-Calvache, A. T., 2012. Comparison of four line-based positional assessment methods by means of synthetic data. *Geoinformatica*, 16, pp. 221-243.
- Baatz, M. & Schäpe, A., 2000. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. (Võrgumaterjal) [http://www.ecognition.cc/download/baatz\\_schaepe.pdf](http://www.ecognition.cc/download/baatz_schaepe.pdf) (05.03.2016).
- Benz, U. C. et al., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry & Remote Sensing*, 58, pp. 239-258.
- Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, pp. 2-16.
- Blaschke, T., Lang, S. & Hay, G. J., 2008. Object-Based Image Analysis. Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Berlin: Springer-Verlag Berlin Heidelberg.
- Burnett, C. & Blaschke, T., 2003. *Ecological Modelling* 168 (2003) 233–249. *Ecological Modelling*, 168, pp. 233-249.
- Chen, G. et al., 2011. A multiscale geographic object-based image analysis to estimate lidar-measured forest canopy height using Quickbird imagery. *International Journal of Geographical Information Science*, 25(6), pp. 877-893.
- Congalton, R. G. & Green, K., 2009. *Assessing the Accuracy of Remotely Sensed Data*. 2nd toim. Boca Raton: CRC Press.
- Eastman, J. R., 2006. *IDRISI Andes Guide to GIS and Image Processing*. Worcester: Clark Labs.
- Goodchild, M. F. & Hunter, G. J., 1997. A simple positional accuracy measure for linear features. *International Journal of Geographical Information Science*, 11(3), pp. 299-306.
- Haralick, R. M., Shanmugam, K. & Dinstein, I., 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3(6), pp. 610-621.
- Hay, G. J. & Castilla, G., 2008. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. rmt:: T. Blaschke, S. Lang & G. Hay, toim-d Object-Based Image Analysis. Berliin: Springer, pp. 75-89.
- Hay, G. J. & Castilla, G., 2008. Image objects and geographic objects. rmt:: T. Blaschke, S. Lang & G. Hay, toim-d Object-Based Image Analysis. Berliin: Springer, pp. 91-110.
- Hellesen, T. & Matikainen, L., 2013. An Object-Based Approach for Mapping Shrub and Tree Cover on Grassland Habitats by Use of LiDAR and CIR Orthoimages. *Remote Sensing*, 5, pp. 558-583.

- Hussain, M. et al., 2013. Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80, pp. 91-106.
- Kolecka, N. et al., 2015. Mapping Secondary Forest Succession on Abandoned. *Remote Sensing*, 7(7), pp. 8300-8322.
- Lang, M., 2013. A simple method for mapping woody plant cover in agricultural fields using airborne lidar. *Forestry Studies*, 58, pp. 5-11.
- Lang, S., 2008. Object-based image analysis for remote sensing applications: modelling reality - dealing with complexity. rmt:: T. Blaschke, S. Lang & G. Hay, toim-d Object-Based Image Analysis. Berliin: Springer, pp. 3-27.
- Lu, D., Moran, E., Hetrick, S. & Li, G., 2011. Land-Use and Land-Cover Change Detection. rmt:: Q. Weng, toim. *Advances in Environmental Remote Sensing: Sensors, Algorithms, and Applications*. New York: CRC Press Taylor & Francis Group, pp. 273-290.
- Maa-amet, 2015c. Eesti topograafia andmekogu - aerolaserskaneerimise kõrguspunktid. Metaandmed. (Võrgumaterjal)  
<http://inspire.maaamet.ee/geoportal/catalog/search/resource/details.page?uuid={62F5D9DF-C65C-4DCE-9888-5F0A67A45E61}> (11.01.2016).
- Maa-amet, 2015e. Eesti topograafia andmekogu metsanduslikud ortofotod. Metaandmed (Võrgumaterjal)  
<http://inspire.maaamet.ee/geoportal/catalog/search/resource/details.page?uuid={4C76E312-B170-449E-9C9E-D510CBCE37C2}> (22.04.2016).
- Maa-amet, 2015b. Eesti topograafia andmekogu tiheasustusalade ortofotod. Metaandmed. (Võrgumaterjal)  
<http://inspire.maaamet.ee/geoportal/catalog/search/resource/details.page?uuid={95935300-277A-4074-94BC-3BC5AF1E7989}> (09.01.2016).
- Maa-amet, 2015a. Eesti topograafia andmekogu topokaardistuse ortofotod. Metaandmed. (Võrgumaterjal)  
<http://inspire.maaamet.ee/geoportal/catalog/search/resource/details.page?uuid={DD75F608-8BDB-4108-A373-1DB5DA4356BC}> (09.01.2016).
- Maa-amet, 2015d. Maa-ameti Geoportaal. (Võrgumaterjal)  
<http://geoportaal.maaamet.ee/est/Andmed-ja-kaardid/Topograafilised-andmed/Korgusandmed/Korgusmudelid-p508.html> (11.05.2016).
- Malinverni, E. S. et al., 2011. Hybrid object-based approach for land use/land cover mapping using high spatial resolution imagery. *International Journal of Geographical Information Science*, 25(6), pp. 1025-1043.
- Marceau, D. J., 1999. The scale issue in social and natural sciences. *Canadian Journal of Remote Sensing*, 25(4), pp. 347-356.
- Marceau, D. J. & Moreno, N., 2008. An object-based cellular automata model to mitigate scale dependency. rmt:: T. Blaschke, S. Lang & G. Hay, toim-d Object-Based Image Analysis. Berliin: Springer, pp. 43-73.

- Peepson, A., Karjatse, M. & Mikk, M., 2015. Nõuetele vastavus ja rohestamine. Tartu: Ökoloogiliste Tehnoloogiate keskus ja Põllumajandusministeerium.
- PRIA, 2016. Toetused - Taimekasvatus. (Võrgumaterjal) <http://www.pria.ee/et/toetused/valdkond/taimekasvatus/> (21.05.2016).
- Remm, K., Remm, J. & Kaasik, A., 2012. Ruumiliste loodusandmete statistiline analüüs. Tartu: Tartu Ülikooli Ökoloogia ja Maateaduste Instituut.
- Richards, J. A., 2013. Remote Sensing Digital Image Analysis. An Introduction. 5th toim. New York: Springer.
- Robertson, L. D. & King, D. J., 2011. Comparison of pixel- and object-based classification in land. *International Journal of Remote Sensing*, 32(6), pp. 1505-1529.
- Rouse, J. W., Haas, R. H., Schell, J. A. & Deering, D. W., 1973. Monitoring Vegetation Systems in the Great Plains with ERTS. *Third Earth Resources Satellite Symposium, Köide I*, pp. 309-317.
- Statistikaamet, 2016. Statistika andmebaas. (Võrgumaterjal) <https://www.stat.ee/34226> (08.01.2015).
- Tamm, M.-C., 2014. Põllumajandusmaa võsastumise monitooring aerolaserskaneerimise andmetega. Tartu.
- Tamm, T., Lang, M. & Metsur, M., 2014. Maa-ameti kaugseireandmete kasutamine ETAKi maakattetüüpide objektipõhisel tuvastamisel. rmt: A. Aan & K. Narusk, toim-d Kaugseire Eestis 2014. Tallinn: Tartu Observatoorium, pp. 104-110.
- Trimble, 2014. eCognition Developer 9.0 Reference Book. München: Trimble Germany GmbH.
- Yang, J., Jones, T., Caspersen, J. & He, Y., 2015. Object-Based Canopy Gap Segmentation and Classification: Quantifying the Pros and Cons of Integrating Optical and LiDAR Data. *Remote Sensing*, 7, pp. 15917-15932.

# Lisad

## Lisa 1. nDSM-ist võsa arvutamise eeskirja dokumentatsioon

```
Classes:
  Maastikuelement
  P
  V
  Võsa maastikuelemendi kõrval

Process: Main:
  Võsa ainult nDSM
  Treenimine
    chessboard segmentation: chess board: 99999 creating 'Level 1'
    assign class by thematic layer: at Level 1: assign class by thematic layer
using "Class"
  classified image objects to samples: at Level 1: classified image objects to
samples
  remove classification: at Level 1: remove classification
  classifier: at Level 1: classifier: train svm using nDSM, nDSM
  Klassifitseerimine
  Segmenteerimine
    multiresolution segmentation: 30 [shape:0.1 compct.:0.5] creating 'Level 1'
  Väikeste segmentide liitmine
    grow region: loop: at Level 1: <- none Area < 100 Pxl
    grow region: loop: at Level 1: <- none Area < 100 Pxl
  Veamaatriksi protseduurid
    assign class by thematic layer: at Level 1: assign class by thematic layer
using "Class"
  classified image objects to samples: at Level 1: classified image objects
to samples
  remove classification: at Level 1: remove classification
  Klassifitseerimine ise
  Võsa ja põld
    classifier: unclassified at Level 1: classifier: apply
    ask question: ask question: "Arvuta veamaatriks"
  Maastikuelemendid
    assign class by thematic layer: at Level 1: assign class by thematic
layer using "Class"
    merge region: Maastikuelement at Level 1: merge region
  Võsa maastikuelementide kõrval
    assign class: P at Level 1: unclassified
    assign class: V with Existence of Maastikuelement (0) = 1 and
Distance to scene border > 0 Pxl at Level 1: Võsa maastikuelemendi kõrval
    assign class: Võsa maastikuelemendi kõrval with Existence of
unclassified (0) = 1 and Existence of V (0) = 0 at Level 1: unclassified
    assign class: loop: Võsa maastikuelemendi kõrval with Existence of V
(0) = 1 and Existence of unclassified (0) = 0 at Level 1: V
    assign class: Võsa maastikuelemendi kõrval with Rel. border to V >
Rel. border to Maastikuelement and Existence of V (0) = 1 at Level 1: V
    assign class: Võsa maastikuelemendi kõrval at Level 1: unclassified
  Eksport
  Segmentide liitmine
    merge region: on Klassifitseerimine V at Level 1: merge region
    merge region: on Klassifitseerimine unclassified at Level 1: merge region
  Generaliseerimine
    pixel-based object resizing: on Klassifitseerimine V at Level 1: grow into
unclassified where rel. area of object pixels in (5 x 5) >0.5
    pixel-based object resizing: on Klassifitseerimine V at Level 1: shrink
using unclassified where rel. area of object pixels in (5 x 5) <0.5
    assign class: V with Area < 1600 Pxl at Level 1: unclassified
  Segmentide liitmine II
    merge region: on Klassifitseerimine unclassified at Level 1: merge region
  export vector layer: V at Level 1: export object shapes to V6sa_nDSMst
  export thematic raster files: V at Level 1: export classification to
V6sa_nDSMstRASTER
```

## Lisa 2. nDSM-ist ja optilistest andmetest võsa arvutamise eeskirja dokumentatsioon

```
Classes:
  Maastikuelement
  P
  V
  Võsa maastikuelemendi kõrval

Process: Main:
  Võsa klassifitseerimine nDSM ja optiliste kaugseireandmetega
    Treenimine
      chessboard segmentation: chess board: 99999 creating 'Level 1'
      assign class by thematic layer: at Level 1: assign class by thematic layer
using "Class"
  classified image objects to samples: at Level 1: classified image objects to
samples
  remove classification: at Level 1: remove classification
  classifier: at Level 1: classifier: train svm using NDVI, NDWI, nDSM, NDVI,
NDWI, nDSM
  Klassifitseerimine
    Segmenteerimine
      multiresolution segmentation: 60 [shape:0.1 compct.:0.5] creating 'Level 1'
    Väikeste segmentide liitmine
      grow region: loop: at Level 1: <- none Area < 100 Pxl
      grow region: loop: at Level 1: <- none Area < 100 Pxl
    Veamaatriksi protseduurid
      assign class by thematic layer: at Level 1: assign class by thematic layer
using "Class"
  classified image objects to samples: at Level 1: classified image objects
to samples
  remove classification: at Level 1: remove classification
  Klassifitseerimine ise
    Võsa ja põld
      classifier: unclassified at Level 1: classifier: apply
      ask question: ask question: "Arvuta veamaatriks"
    Maastikuelemendid
      assign class by thematic layer: at Level 1: assign class by thematic
layer using "Class"
      merge region: Maastikuelement at Level 1: merge region
    Võsa maastikuelementide kõrval
      assign class: P at Level 1: unclassified
      assign class: V with Existence of Maastikuelement (0) = 1 and
Distance to scene border > 0 Pxl at Level 1: Võsa maastikuelemendi kõrval
      assign class: loop: on Klassifitseerimine V with Existence of Võsa
maastikuelemendi kõrval (0) = 1 and Existence of V (0) = 0 at Level 1: Võsa
maastikuelemendi kõrval
      assign class: loop: on Klassifitseerimine Võsa maastikuelemendi kõrval
with Existence of unclassified (0) = 1 and Existence of V (0) = 0 at Level 1: unclassified
      assign class: loop: on Klassifitseerimine Võsa maastikuelemendi kõrval
with Existence of V (0) = 1 and Existence of unclassified (0) = 0 at Level 1: V
      assign class: loop: Võsa maastikuelemendi kõrval with Rel. border to V
> Rel. border to Maastikuelement and Existence of V (0) = 1 at Level 1: V
      assign class: Võsa maastikuelemendi kõrval at Level 1: unclassified
  Eksport
    Segmentide liitmine
      merge region: on Klassifitseerimine V at Level 1: merge region
      merge region: on Klassifitseerimine unclassified at Level 1: merge region
    Generaliseerimine
      pixel-based object resizing: on Klassifitseerimine V at Level 1: grow into
unclassified where rel. area of object pixels in (5 x 5) >0.5
      pixel-based object resizing: on Klassifitseerimine V at Level 1: shrink
using unclassified where rel. area of object pixels in (5 x 5) <0.5
      assign class: V with Area < 1600 Pxl at Level 1: unclassified
    Segmentide liitmine II
      merge region: on Klassifitseerimine unclassified at Level 1: merge region
      export vector layer: on Klassifitseerimine V at Level 1: export object shapes
to V6sa_optiline_ndsm
```

## **Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks**

Mina, Villem Voormansik,

annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) enda loodud teose „Võsastumise tõttu muutunud põllupiiride objektipõhine tuvastamine kaugseire andmetel“, mille juhendajad on Tanel Tamm ja Martin Jüssi,

- 1.1.reprodutseerimiseks säilitamise ja üldsusele kättesaadavaks tegemise eesmärgil, sealhulgas digitaalarhiivi Dspace'is lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;
- 1.2.üldsusele kättesaadavaks tegemiseks Tartu Ülikooli veebikeskkonna kaudu, sealhulgas digitaalarhiivi Dspace'i kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.
2. Olen teadlik, et punktis 1 nimetatud õigused jäävad alles ka autorile.
3. Kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest tulenevaid õigusi.

Tartus, **23.05.2016**