



EESTI MAAÜLIKOOL

Metsandus- ja maaehitusinstituut

Uku Meriloo

**KAUGSEIRE RAKENDAMINE METSA TAKSEERIMISEL
EESTI OLUDES**

REMOTE SENSING APPLICATIONS FOR FOREST INVENTORY IN
ESTONIA

Bakalaureusetöö

Metsanduse õppekava

Juhendaja: dotsent Mait Lang, *PhD*

Tartu 2019

Eesti Maaülikool Kreutzwaldi 1, Tartu 51014		Bakalaureusetöö lühikokkuvõte	
Autor: Uku Meriloo		Õppekava: Metsamajandus	
Pealkiri: Kaugseire rakendamine metsa takseerimisel Eestis oludes			
Lehekülgi: 43	Jooniseid: 6	Tabeleid: 3	Lisaid: -
<p>Osakond / Õppetool: Metsakorralduse ja metsatööstuse õppetool ETIS-e teadusvaldkond ja CERCS-i kood: Metsakasvatus B430 Juhendaja: dotsent Mait Lang, <i>PhD</i> Kaitsmiskoht ja -aasta: Tartu 2019</p>			
<p>Käesoleva bakalaureusetöö eesmärk oli anda ülevaade metsamajandusliku kaugseire tehnikast ja meetoditest ning rakendamisest Eestis, kasutades referentsiks metsade kaugseiret kirjeldanud uurimusi mitmetest erinevatest riikidest.</p> <p>Põhjaliku ülevaate saamiseks kasutati teadustöid Eestist ning välismaalt. Käesolevas töös on refereeritud uurimusi, mis sidusid endas metsamajanduslikku kaugseiret ja metsade takseerimist. Erinevate uurimuste läbi töötamine andis kinnitust, et võrreldes välismaal tehtud metsade kaugseire rakenduslike uurimustega, on Eestis läbi viidud teadustööd olnud väga hea rakendusliku potentsiaaliga. Tehnika ning teaduse arenguga suureneb ka vajadus üha täpsemate metsade inventeerimisandmete järgi, seega on inventeerimisandmete kvaliteedil tähtis osa tõhusa metsamajandusliku kaugseire toimimiseks.</p>			
Märksõnad: kaugseire, metsamajandus, takseerimine, metsakorraldus			

Estonian University of Life Sciences Kreutzwaldi 1, Tartu 51014		Abstract of Bachelor's Thesis	
Author: Uku Meriloo		Curriculum: Forest management	
Title: Remote sensing applications for forest inventory in Estonia			
Pages: 43	Figures: 6	Tables: 3	Appendixes: -
Chair: Chair of Forest Management Planning and Wood Processing Technologies			
Field of research and (CERCS) code: Sylviculture B430			
Supervisor: Mait Lang, <i>PhD</i>			
Place and date: Tartu 2019			
<p>The aim of this bachelor thesis was to give a general overview of remote sensing technology, methods and applications for forest inventory in Estonia.</p> <p>Diferent scientific articles on remote sensing in forestry were used which assessed the combination of forest inventory and application of remote sensing in forestry. These articles were from Estonia and from abroad. Conclusion of collating these articles, was that remote sensing in forestry in Estonia has been well applied to resolve multiple issues in forest management. The growing need of accurate forest inventory data for algoritm training will be one problem to solve to increase the efficiency of remote sensing-based estimates in the future.</p>			
Keywords: remote sensing, forest management, forest inventory			

SISUKORD

SISUKORD	4
SISSEJUHATUS	5
1 KIRJANDUSE ÜLEVAADE.....	6
1.1 Eesti metsasus	6
1.2 Metsade korraldamine.....	8
1.3 Kaugseire kasutusala.....	12
1.4 Satelliitkaugseire.....	13
1.4.1 Ülevaade satelliitkaugseire tehnikast.....	13
1.4.2 Kaugseirega takseerandmete määramine.....	17
1.4.3 K-NN meetod	18
1.4.4 Väljakutsed satelliitkaugseire rakendamisel metsakorraldamises	19
1.5 LiDAR (<i>Light Detection And Ranging</i>).....	20
1.5.1 Ajalugu	20
1.5.2 Ülevaade.....	20
1.5.3 Puistu liigilise koosseisu määramine.....	23
1.5.4 Puistu kõrguse ja tüvemahu määramine	24
1.5.5 Biomassi määramine	25
1.6 Kaugseirepildid ja LiDAR andmestik kombineerituna.....	27
1.7 Aerofotograafia ja aerofotogramm-meetria	29
1.8 Kaugseire kasutamine takseerimisel Eestis	31
1.8.1 Eesmärgid.....	31
1.8.2 Hetkeseis	32
1.8.3 Tulevik.....	33
2 ARUTELU	34
3 KOKKUVÕTE	36
4 KASUTATUD KIRJANDUS	37

SISSEJUHATUS

Meteoroloogia, geoloogia, bioloogia, demograafia, kartograafia – on vaid mõned teadusharud, mis kasutavad infoallikaks kaugseiret ning sinna juurde mudelite koostamist. Kaugseire andmete abil mudelite ehitamine on mitmete meile igapäevast informatsiooni pakkuvate teadusharude juures igapäevatööks. Meile nii tavalisena tunduv ilma prognoosimine põhineb valdavalt satelliidipiltide töötlemisel ning sealt kogutud andmete viimisel ilma mudelitesse. Samad meetodid on välja töötatud ka metsade kaugseires, kus ilma prognoosimise asemel tegeletakse metsade kasvu prognoosimisega ning metsade hetkeseisu iseloomustamisega.

Metsade kaugseire on valdkond, millega on tegeletud juba üle 30 aasta, kuid viimase 10 aasta jooksul on selle rakendamine jõudsalt kasvanud. Metsade majandamine ning puiduvarumine vajavad kasvavas tarbimisühiskonnas järjest ajakohasemaid monitoorimisvõimalusi. Samuti seisame silmitsi kiirete kliimamuutustega, mille mõjudest on võimalik aru saada süsinikuringe uurimisega. Ka selles osas nähakse potentsiaali kaugseirel. Kaugseire areng metsanduslikus vaates on hetkel punktis, kus järgmise kümnendi jooksul oodatakse rohkesti uusi ja täpsemaid rakendusi metsastatistika kogumiseks. Palju lootusi on pandud mehitamata õhusõidukite kasutuselevõtmisele ja kvaliteetsemad andmestikke loovatele satelliidi sensoritele ja laserskanneritele. Selle juures muutub ka looduses tehtavate mõõtmiste kvaliteet ja eesmärk, mis omavad kriitilist tähtsust kaugseire andmetel põhinevate hinnangute täpsusel.

Käesolev töö annab referatiivse ülevaate Eesti metsade arengust, metsakorraldusest ning kaugseiretehnikatest nii Eestis kui välismaal, kasutades selleks suures osas teaduslikke artikleid. Töö eesmärk on hinnata metsamajandusliku kaugseire arengut ning leida teadustöödest kaugseire tehnikaid, mida on rakendatud ja mida saaks rakendada metsade takseerimisel Eestis.

1 KIRJANDUSE ÜLEVAADE

1.1 Eesti metsasus

Metsade majandamine ja puidu varumine on Eestis juba sadu aastaid olnud üks tulusamaid majanduslikke tegevusi. Eelmise sajandi alguses ekspuateriti metsa lausa nii võimsalt, et metsade pindala riigi kogupindalast oli ligi 20% (Pärt 2008). Metsasuse vähenemist põhjustas ka 1914. aastal alanud I Maailmasõda, mille tagajärjel jäid metsakasvatustööd pooleli, samal ajal kui metsaressursi kasutamine ei raugenud (Meikar 2018). 20. sajandi algul oli väga keeruline teha kogu Eestit hõlmavat metsapindala hindamist, kuna vahendid selleks puudusid. Info metsade kohta saadi maahindamiste järgi, mis olid suuremas osas Põhja-Eestis ja Liivimaal tehtud, välja arvatud Saaremaal. 1920ndatel avaldatud statistika, kus Põhja-Eesti ja Liivimaa metsasust kokku hinnati 20% juurde, ei ole ilmselt väga täpne, kuna Põhja-Eesti metsade hindamine tehti 19. sajandi lõpul ning Liivimaal 20. sajandi alguses ja lisaks ei määratletud metsamaad igas piirkonnas samade kriteeriumite järgi (Pärt 2008). Uuritud on ka 1924. aastal kehtinud erinevaid maakatastreid ning üheks madala metsasuse hinnangu põhjuseks saab tuua ka puisniitude ja metsakarjamaade suure osakaalu – maakasutus, mida tänapäevase Metsaseaduse järgi saaks määratleda metsaks, kuid sel ajal mitte (Kalle 2018; Meikar 2018). Metsamajandamise uuele hingamisele panid aluse 1918 asutatud Riiklik metsavalitsus, kui ka 1920 loodud Tartu Ülikooli metsaosakond ja esimene metsakorralduseeskiri (100 aastat Eesti metsa lugu 2019). Enne teist maailmasõda ulatus Eesti metsasus juba 33%-ni, milles oli oma osa kuivenduskraavide ehitamisel, teisalt aga paranenud metsastatistikal. Metsamaade pindala kasv jätkus ka sellele järgnenud Nõukogude aja teisel poolel (Pärt 2008). Metsasuse suurenemisele on kaasa aidanud mitmeid tegureid – kaks maa,- ja põllumajandusreformi Nõukogude ajal ning maareform ja põllumajanduse ümberorganiseerimine 1990ndatel. Oluliseks teguriks saab tuua ka mahuka metsade ja soode kuivendamise 1960-1980 aastatel, mis tõi kaasa nii metsapindala,- kui ka metsatagavara kasvu (Eesti Metsavarud 2008; Kalle 2018).

Eelmise sajandi esimesel poolel tehti metsade statistika kogumiseks ränka tööd – kogu andmestik saadi läbi puuteseire ehk looduses ülepinnaliste mõõtmiste tegemisega ning nende mõõtmiste hilisemate töötlemistega. Kuna töö oli väga ajakulukas, siis paljude mõõdetud maatüki maakasutus jõudis selleks ajaks muutuda, kui ametlik statistika välja tuli (Pärt 2008). Tänapäeva metsainventeerimise juures kasutakse metoodikat ning tehnikat, mille kaudu on võimalik metsa statistilised näitajad kokku koguda üsna kiiresti ning madala veaprotsendiga. Siiski, mida täpsemat andmestikku me metsast tahame, seda täpsem peab olema tehnika, mida selle juures kasutame ning metoodika, mille kaudu vajalikud andmed välja tuuakse.

1.2 Metsade korraldamine

Praktilise metsakorralduse kohta on Eesti aladelt esimesi märke aastast 1788, kui esimest korda eraldati aastalangid ning praeguste Põhja-Läti aladel, toonases Lenzenhofis, lasi parun Campenhausen oma metsad ära korraldada. Üldjuhul peeti sellel ajal heaks peremeheks seda mõisnikku, kes oma metsad võimalikult kiiresti põllumaaks raadas (Daniel 2001). Metsade korraldamine koosneb nende mõõtmisest, planeerimisest ning raiest. Metsade mõõtmine ehk takseerimine ongi ehk üks olulisem osa metsakorraldusest, kuna see annab sisendi ülejäänud metsakorralduslike tööde tegemiseks. Eestis käib metsakorraldus puistupõhiselt - puistu tähendab sarnase iseloomuga metsaosa (sarnane liigiline koosseis, vanus, kõrgus, kasvukohatüüp)(joonis 1).



Joonis 1. Järvelja kvartalist 222 tehtud puistupõhised eraldised. Eraldised on nummerdatud ning välja toodud peapuuliik. Pildilt on võimalik ka visuaalselt eristada puistuid värvi, struktuuri ja katvuse järgi. Ortofoto on pärit Maaameti kogust ning peapuuliigid Metsaregistri kaardirakendusest.

Metsatakseerimine on üldjoontes metsa iseloomustamine – rindelisuus, nende liigiline

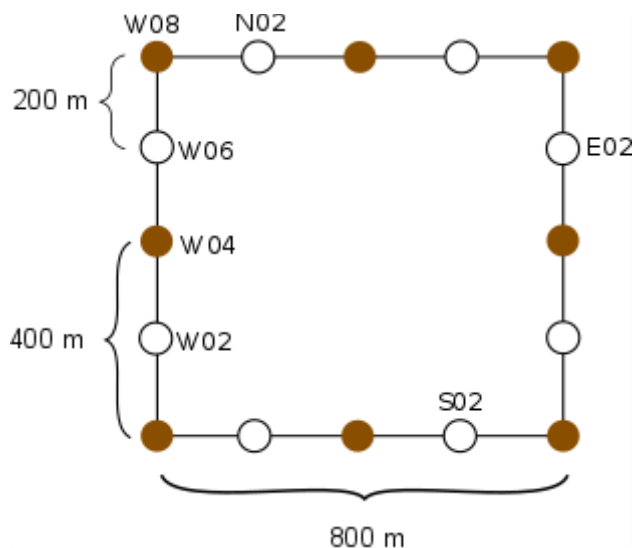
koosseis, keskmine kõrgus, vanus, rinnasdiameeter ja tagavara. Lisaks saab takseerimise tulemusena teha hinnanguid tulevikuks – milliseid tagavarasid on oodata ning millal antud puistu küpseks saab (Vaus 2005).

Metsa inventeerimine on Eestis määratletud “Metsa korraldamise juhendis”. Inventeerimise eesmärk on, lisaks varem kirjeldatule, koguda andmeid metsa seisundi ja asukoha kohta ning alginformatsiooni kogumine metsaomanikule metsamajanduskava koostamiseks (Metsa korraldamise juhend 2018).

Eestis inventeeritakse metsa kahel viisil – ülepinnalise takseerimisega, mille käigus kogutakse puistukaupa takseerandmed – rinnete arv, rinnete liigiline koosseis, keskmine kõrgus,-vanus,-rinnasdiameeter jm - selle kaudu tekib puistu takseerikirjeldus. Antud lahendust kasutatakse enamasti uute eraldiste kaardistamisel ning metsamajanduslike tööde planeerimisel. Ülepinnalisel inventeerimisel kasutatakse metsa silmamõõdulist takseerimist ning lisaks sellele mõõdetakse ja loendatakse kindlad andmed (puude vanus,- kõrgus,- rinnasdiameeter,- arv)(Metsa korraldamise juhend 2018). Takseerimine piirdub eraldistega – Eestis on enamasti iga puistu käsitletud eraldisena.

Et saada Eestis tunnustatud metsakorraldaja litsents, on vaja sooritada selleks teoreetiline eksam ning katsetöö, mis tähendab etteantud puistu takseerikirjelduse esitamist. Seisuga 19.12.2018 on Eestis tunnustatud metsakorraldajaid 243 (Keskkonnaagentuur 2018b). Metsakorraldajatele tehtavad katsed peaksid tagama selle, et kõik litsentsi saanud metsakorraldajad näeksid välitöid tehes puistu takseertunnused samamoodi. Kaugseire andmete sidumisel inventeeritud andmetega on äärmiselt oluline, et inventeeritud andmed kirjeldavad antud puistut või proovitükki võimalikult täpselt, et tagada prognooside täpsus.

Peale taasiseseisvumist pidi Eesti riik kasutusse võtma uue üleriigilise metsade monitoorimise viisi, kuna algas maade tagastamine õigusjärgsetele omanikele ning oli vaja süsteemi, mis hõlmaks nii era,- kui riigimetsi. Selleks puhuks laenati teadmisi meie naabritelt Rootsist, kellel on pea saja aastane riikliku metsade statistika koostamise kogemus (Sims 2018b). SMI ehk statistiline metsa inventeerimine on 1999. aastal riigi poolt algatatud süstemaatiline metsade inventeerimine, mille eesmärgiks on ülevaate saamine Eesti metsadest ning nende seisundist. Süsteem on pärit Rootsist, kus selle kaudu on metsastatistikat tehtud juba ligi sada aastat (Sims 2018a). Statistiline metsainventuur on sisuliselt valikuuring, mille jaoks on tehtud 4000 proovitükki üle Eesti, mis annavad metsapindala mõõtmisele 1,5% vea ning metsatagavara mõõtmisele kuni 5% vea piiri. Trakt on 800×800 m suurune ala, mille äärtes mõõdetakse kasvukoha- ja tagavaraproovitükke, mis asuvad üksteisest 200 m kaugusel (joonis 2). Nagu nimigi ütleb, annavad erinevad proovitükid erinevat infot – kasvukoha proovitükil määratakse selle kasvukohatüüp ning tagavara proovitükil mõõdetakse kõik puud ning arvutatakse nende tagavara. Pooled traktid on alalised ja pooled ajutised. Ülevaatlikemate andmete saamiseks mõõdetakse alalistel traktidel iga viie aasta tagant, aga ajutistel traktidel vaid ühe korra. (Sims 2018a).



Joonis 2. Traktil paiknevad proovitükid (Sims 2018b).

Metsade inventeerimine riiklikul tasemel annab aluse arengukava koostamisele ning metsapoliitika loomisele. Strateegiliselt tähtsamad takseertunnused, mille hinnangud metsade inventeerimine tagab, on tänapäeval metsasuse protsent, metsade tagavara, metsade biomass, süsiniku sidumise võime ja majanduslikult poolelt – metsade tootlikkus (White et al. 2016). Metsade inventeerimine on siiski tänaseni väga mahukas, kallis ning ajakulukas töö. On välja selgitatud, et metsataksaator suudab päevas inventeerida kuni 30 hektarit metsa ja inventeerimise mahu tõstmine ei tõsta oluliselt inventeerimise produktiivsust (Mäkelä ja Pekkarinen 2004). Siinkohal tekib vajadus parema inventeerimise meetoodika järele. Suurtes metsariikides nagu Soome, Rootsi, Kanada ja USA on metsade inventeerimisel suur rõhk pandud metsade kaugseirele, mis kärbib inventeerimiseks tehtavaid kulusid, säästab tööjõudu ning annab tulemusi lühemate perioodide kohta. Tavaliseks kombinatsiooniks on saanud metsainventeerimise andmestiku sidumine satelliidipiltide andmestikuga. See ei ole aga alati andnud piisavalt väikse hajuvusega tulemusi väiksemate metsa-alade kogutagavara arvutamisel, kus on tekkinud 60% kuni 80% viga. Siiski saab täpsemaid hinnanguid, kui uuritavat ala laiendada suurematele aladele – üle 30 hektari suuruse ala uurimisel langes vea suurus juba 20%-le (Mäkelä ja Pekkarinen 2004).

1.3 Kaugseire kasutusala

Kaugseirega tegelevad kõik terve nägemismeelega inimesed iga päev. Kaugseire on objektide uurimine ilma puutekontaktita – seega kõik, mida me nägemisega tuvastame, on kitsas mõttes kaugseire. Täpsemalt on kaugseire eemal asuvate objektide kohta teabe kogumine ning ka selle teabe töötlemine. (Nilson 1994)

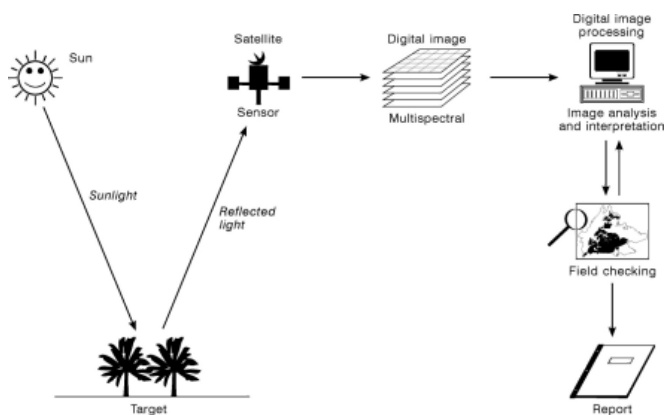
Kaugseiret kasutatakse loodusvarade hindamisel, jälgimisel ning prognoosimisel. Väga tähtis osa on kaugseirel näiteks meteoroloogiliste prognooside tegemisel, veekogude seisundi hindamisel ning loodusvarade monitoorimisel. Üks hinnalisemaid loodusvarasid meie planeedil on puittaimestik (Gisgeography 2019). Taastuva loodusvarana, on puitu hinnatud ehitusmaterjali- ning kütteallikana juba tuhandeid aastaid. Iga aastakümnega leitakse puidule uusi kasutusviise ja seeläbi leiab puit rohkem rakendust, mis omakorda seab suurema surve õigete metsamajanduslike otsuste tegemisele. Selleks on metsakasvatajatel vaja võimalikult täpset hinnanguid metsa takseertunnuste kohta.

Metsamajanduslik kaugseire annab võimaluse määrata homogeensete metsaosade piire, puuliike, puude kõrgust, tihedust ja hinnata metsa biomassi, mis omakorda annab infot süsinikvarude kohta (Lang et al. 2016). Pikas perspektiivis on kaugseire heaks infoallikaks puistute kasvu ja seisundi prognoosimisel. Suurte metsamassiivide puhul on kaugseirel tähtis osa ka nende monitoorimisel – ligipääsmatud kohad ning homogeensed puistud, mille takseerimiseks pole mõtet inimressurssi raisata. Suureks abiks on satelliitkaugseire ka metsandusliku statistika tegemisel. Eriti väljub see raiete, metsakahjustuste ja tulekahjude monitoorimisel (Nilson 1994). Taolised häiringud on satelliitpiltidelt enamasti hästi näha ning GIS tarkavaraga ka üsna mugav tuvastada ja töödelda. Metsandusliku kaugseire täpsus paraneb iga aastaga, sest arenevad sensorid, kasutusele võetakse rohkem satelliite, leitakse uusi meetodeid puuliikide klassifitseerimiseks, metsas puidu arvutamiseks, puistute piiride leidmiseks ning luuakse mudeleid, mis kombineerides kvaliteetsete inventeerimisandmetega annavad üha täpsemaid metsade takseerandmeid.

1.4 Satelliitkaugseire

1.4.1 Ülevaade satelliitkaugseire tehnikast

Passiivne optiline kaugseire kasutab ära maapinnalt peegelduvat elektromagnetkiirgust ning sensorid, mis eristavad ultraviolettkiirgust, infrapunakiirgust ning lähis-infrapunakiirgust, soojuskiirgust ja võimaldavad salvestada infot ja seeläbi kuvada satelliidipildidel objektid erineva spektraalse heledusega. Kirjeldatud meetodit nimetatakse passiivseks, sest kiirgus, mida sensor vastu võtab, on looduslik, mitte masinate poolt emiteeritud (joonis 3; Centre for Remote Imaging... 2001b; Federal Institute for Geosciences... 2019).




Joonis 3. Satelliitkaugseire protsess (Worman ja McMorrow 2002).

Optilisi sensoreid on erinevaid – nad eristuvad nii tööpõhimõttelt, kui ka tehnoloogiliselt arengult. Erinevad optilised sensorid spektraalse lahutuse järgi:

- 1) Pankromaatiline süsteem;
- 2) Multispektraalne süsteem;
- 3) Superspektraalne süsteem;
- 4) Hüperspektraalne süsteem;

Pankromaatiline süsteem koosneb ühe kanaliga sensorist, mis on tundlik suurele lainepikkuste vahemikule, kuid erinevate spektrivahemikke ei erista. Selline on näiteks: IKONOS PAN. Multispektraalsel süsteemil on mitme spektraalse kanaliga sensor, mis on tundlik mitmele kitsale lainepikkuse vahemikule. Antud sensor loob nii öelda mitmekihilise andmestiku, mis koosneb erinevate spektrivahemike mõõtmiste tulemuste kihtidest. Sellised on näiteks: Landsat-8 OLI, Sentinel-2 MSI, IKONOS MS. Superspektraalsel skanneril on mitukümmend kanalit ning see tuvastab veel kitsama lainepikkusega vahemikke kui multispektraalne sensor, mis tagab veel täpsema spektraalse andmestiku. Näiteks: Terra satelliidil paiknev MODIS skanner ning ENVISAT satelliidil paiknev MERIS instrument. Hüperspektraalne sensor, ehk spektromeeter, tuvastab sada või enam erinevat lainepikkuse vahemikku ja seeläbi annab väga mahuka ning täpse andmestiku. Näiteks: AVIRIS, mida kasutatakse lennukitelt seirete tegemiseks ja Hyperion, mis asub satelliidil EO-1 (NASA 2019a; The EO-1 Hyperion Imaging Spectrometer 2019; Centre for Remote Imaging... 2001b).

Passiivse kaugseire kõrval on olemas aktiivne kaugseire. Aktiivse kaugseire all peetakse eelkõige silmas radari antenni poolt välja saadetud mikrolaine impulsse, mis saadetakse satelliidilt või lennuki radarilt Maa poole ning registreeritakse sealt tagasi hajunud impulsid (joonis 4; Federal Institute for Geosciences...2019). SAR (*Synthetic Aperture Radar*) on satelliidil paikneva radari süsteem, mis töötati välja 1950ndatel aastatel USA militaarsektori poolt pideva kaugseire tegemiseks. Pideva kaugseire tagavad mikrolained, mis suudavad tungida läbi pilvede – seega saab vaatlusi teha ka pilvkatte olemasolul. Probleem, millega SARi kasutusele võtmisega silmitsi pidi seisma oli radari antenni suurus. Piisava ruumilise resolutsiooni tagamiseks pidi SAR olema umbes jalgpalliväljaku suurune ning seda mõõtu radarit ei suutnud lendu tõsta ükski selle aja lennuk. Selleks mõtles Ameerika Ühendriikide insener Carl Wiley välja printsiibi, et kuna iga tagasi radari poole peegelduv impulss on peegelduse tekitanud objekti tõttu erineva doppleri efekti nihkega, saab läbi sageduste analüüsi kokku panna detailse kujutise (Engineering and Technology... 2009).



Joonis 4. Radari poolt välja saadetud mikrolainete tagasi hajumine maapinnalt (Centre for Remote Imaging... 2001a).

Puistu liigilist tagavara, kõrgust, rinnaspindala ning rinnasdiameetri korrelatsiooni satelliitkaugseire käigust saadud satelliidipiltidelt saadavate tunnustega, on uuritud juba 1970ndatest, kuid kvaliteetsed kosmosepildid tulid koos 1980ndate keskel orbiidile saadetud Landsat-5 TM-i ja SPOT HRV (*High Resolution Visible*) instrumentidega. Landsat-5 TM (*Thematic Mapper*) saadeti USA kosmoseagentuuri NASA (*National Aeronautics and Space Administration*) missiooni käigus orbiidile 1984. aastal ning oma 28 aastase tööaja jooksul tegi see satelliit 150 000 orbiidi ringi ning jäädvustas 2,5 miljonit kosmosepilti (NASA 2013). SPOT-1 satelliit koos HRV instrumendiga jõudis orbiidile 1986. aastal ning selle missiooni eestvedajaks oli CNES (Prantsusmaa kosmoseagentuur) koos Belgia ja Rootsi teadusasutustega. SPOT-1 HRV tegi 17 aasta jooksul kokku 2,7 miljonit kosmosepilti ning lõpetas töö aastal 2003. SPOT-1 HRV oli esimene tsiviilkasutuses skanner, mis tegi kosmosepilte ruumilise lahutusega 10-20 m (European Space Agency 2019a).

Metsandusliku kaugseire jaoks oli tähtis aasta 1999, kui orbiidile saadeti satelliit IKONOS, millel oli esimene vabakasutusel olev kõrge ruumilise lahutusega sensor (<10m) (White et al. 2016). Tänapäevaks on vabakasutusel mitmeid pildikogusid, mis on tehtud multispektraalsete skanneritega nagu näiteks Landsat-8 OLI ja Sentinel-2 MSI (tabel 1). Mõlemad satelliidid oma oma seeria uusimad kasutuses olevad instrumendid. Landsat-8 saadeti orbiidile 2013. aastal ning selle orbiidi kaugus Maast on 705 km. Landsat-8 pardal on sensor OLI (*Operational Land Imager*), millel on 9 erinevat spektraalkanalit ning lisaks

kaks termilise infrapuna kanalit (U.S. Geological Survey 2017). Sellest mõnevõrra uuem optilise sensoriga varustatud satelliit Sentinel-2A startis orbiidile 2015. aastal ning liigub orbiidil kõrgusega 786 km. Sentinel-2A pardal on MSI (*Multi-Spectral Instrument*) nimeline sensor, mis suudab jäädvustada 13 spektraalkanalit (European Space Agency 2019b).

Tabel 1. Satelliitskannerite OLI ja MSI võrdlus. (NASA 2019b; European Space Agency 2019b)

Tunnus	Landsat-8 OLI	Sentinel-2A MSI
Spektraalkanaleid	9	13
Skanneerimisulatus (km)	185	290
Pankromaatiline resolutsioon (m)	15	-
Termilised spektriosa kanalid	2	-
Orbiidi kõrgus merepinnast (km)	705	786
Maksimaalne ruumiline resolutsioon (m)	15(PAN)	10
Orbiidile saatmise aasta	2013	2015

Astola et al. (2019) uurisid eelnevalt kirjeldatud satelliitidel olevate skannerite tööd. Aluseks võeti see, kui hästi sensorite andmestiku järgi saab prognoosida metsainventeerimisel kasutatavaid takseertunnuseid. Katses kasutati kaht masinõppe mudeli meetodit – MLP (*Multilayer Perceptron*) ja regressioonipuu (*regression tree*). Tulemusena tõdeti, et Sentinel-2A MSI tehtud ülesvõtted andsid täpsemaid tulemusi kui Landsat-8 OLI andmestik. Põhjuseks toodi suures osas just tehnilised näitajad – Sentinel-2A satelliidil paikneval skanneril on rohkem kanaleid (13) ning enamikes neist on parem piksli ruumiline resolutsioon.

1.4.2 Kaugseirega takseerandmete määramine

Takseertunnuse väärtused ei ole otseselt seotud uurimisobjektilt peegeldunud kiirgusega. Küll aga on uuritava puistu takseerkirjeldus kaudselt korrelatsioonis sealt peegeldunud kiirguse heledusega (Nilson 1994). Metsamajanduliku satelliitkaugseire põhimõte on anda kaugseire käigus töödeldava kujutise igale pikslile reaalsest metsast mõõdetud arvulised väärtused. Satelliidipildile peaks üks puistu jääma sama heledusega – kuna puistu koosneb sarnase liigi, vanuse ja kasvuga puudest. Seeläbi antakse igale pikslile oma tunnusvektor ehk spektraalsignatuur, mis peaks iseloomustama selle puistu kõiki takseertunnuseid. Ühe võimalusena kasutatakse mudelit, mis annab igale pikslile kindla klassi, võtteks aluseks spektraalsignatuuriga määratletud pikslid (European Space Agency 2014).

Metsatakseerimisel on ehk üks esimesi küsimusi – milline on puistu liigiline koosseis. Optilise kaugseire puhul on metsade liigilise koosseisu määramiseks kindlad lainepikkustevahemikud, mis toovad välja erinevate puuliikide tunnused. Puude lehed paistavad oma nähtava valguse neeldumise ning rohelise spektrivahemiku peegeldamise tõttu kõige paremini välja 400-700 nm lainepikkusel ning lisaks sellele on lehtedes sisalduv vesi see, mis toob lähis-infrapunases vahemikus neeldunud kiirguse puudumise tõttu puulehed esile (Fassnacht et al. 2016).

Metsamajanduslikult on tähtis kindlaks teha, kas uuritavas puistus on tegu okaspuu või lehtpuu enamusega. Satelliidipiltidelt tulevad okaspuu ja lehtpuude erinevused kõige paremini välja lähis-infrapunapiirkonnast. Lehtpuud paistavad seal heledamad ning okaspuud tumedamad. Eestis põhiliste okaspuuliikide, hariliku männi ja hariliku kuuse, erinevus tuleb välja aga keskmises infrapunapiirkonnas. Erinevus tekib tänu lähis-infrapuna kiirguse erinevale peegeldumisele lehtedelt ning okaspuuvõradelt, lisaks võrade tiheduse erinevusele (Nilson 1994). Valevärvipildid on metsamajanduslikus kaugseires enim kasutatust leidnud töödeldud aero-ja satelliidipildid. Mitmed olulised taimkatet iseloomustavad tunnused, nagu puude lehtede ja okaste erinev toon, tõusevad esile spektrivahemikes, mida inimsilm ei tuvasta (nagu näiteks: infrapuna-, lähis-infrapuna- ja lühilaineline infrapunakiirgus). Selleks luuakse valevärvipildid, kus inimsilmale tuvastamatud spektrivahemikud asendatakse kindla nähtava spektrivahemikuga (Maaameti Geoportaal 2018).

Lang et al. (2018) tegid katse, kus lausmetsakorralduse andmetest võetud näidiste, digitaalse mullakaardi ja multispektraalsete satelliidipiltide põhjal koostati Eesti puistute liigilise koosseisu kaart. Tulemuste kinnitamiseks kasutati statistilise metsainventuuri proovitükke. Puistute koosseisu prognoosimiseks kasutati juhusliku metsa (*random forest*) algoritmil baseeruvat masinõppe meetodit. Tulemused näitasid tugevat korrelatsiooni treenitud mudelil põhineva prognoosi ning mõõdetud andmete vahel. Täpsemad oli tulemused põhiliste puuliikide nagu hariliku männi, hariliku kuuse, kase ja haava osas.

1.4.3 K-NN meetod

K-NN (*k- nearest neighbours*) ehk K- lähima naabri meetod on metsade kaugseires üks enim kasutatud masinõppe meetodeid klassifitseerimiseks ja regressiooniks (Altman 1992). Meetod seisneb selles, et kosmosepildi andmestik seatakse reaalselt metsas mõõdetud näidispuistu takseerikirjeldusega. Kui ühe puistu kohta on kindlatele pikslitele mõõdetud takseerikirjeldus antud, siis hakatakse pilti pikselhaaval töötlemas ning igale pikslile antakse (3-5) spektraalselt kõige lähema proovitüki takseerikirjelduse keskmine väärtus (Lang et al. 2011; Lang ja Arumäe 2014). K-NN meetodi kasutamisega tulevad kaasa ka mõned probleemid, mis just Eesti metsade osas võivad kaasa tuua valesid tulemusi: meetod ei anna üksikpuistute hindamisel ennustatud tulemitele piisavalt väikse hajuvusega hinnanguid (Katila ja Tomppo 2001; Lang et al. 2011).

1.4.4 Väljakutsed satelliitkaugseire rakendamisel metsakorraldamises

Satelliitkaugseire rakendamine puistutele hinnangute andmisel on viimase 35 aastaga teinud läbi suure arengu. Üha enam metsamajandusliku kaugseire alaseid uurimusi viiakse läbi kasutades hüperspektraalset andmestikku. Multispektraalsetelt- ja eriti hüperpektraalsetelt fotodelt on võimalik registreerida täpsemaid klassifitseerimistunnuseid kui LiDAR ja SAR andmetega (Fassnacht et al. 2016). Ka sobivad kõrge spektraalse resolutsiooniga skannerid (MODIS sensor- 250 m kuni 1000 m ruumiline resolutsioon, 36 kanalit, spektraalne resolutsioon 390–1040 nm) paremini esile tooma spektraalseid signatuure erinevatel kasvukohtadel, milles kõrge ruumilise resolutsiooniga seadmed nii häid tulemusi ei anna (Rocchini et al. 2013).

Kaugseire suuremad väljakutsed on kaugseirepiltide korrigeerimine, ning nendelt vajalike biofüüsiliste tunnuste ja muutuste tuvastamine. Ka on üha aktuaalsem kaugseire kaudu ökosüsteemide mitmekesisuse ja kvaliteeti hindamine (Mairota et al. 2015).

Rocchini et al. (2013) võtsid vaatluse alla diskreetsete klasside kasutamise kaugseire piltide klassifitseerimisel. Diskreetsel klassifitseerimisel antakse igale pikslile kindla klassi väärtus. Probleem seisneb selles, et loodusest on raske leida diskreetseid mustreid, kus klassid on omavahel eristuvad. Seega ei saa olla olukorda kus üks klass piksli kirjeldamiseks on õige ning kõik teised klassid absoluutselt valed.

Piksli tasemel tekivad üsna suured hinnangu vead. Need on põhjustatud pildi georegistreerimise- ning proovitükkide paiknemise vigadest. Seega võib juhtuda et proovitükil tehtud mõõtmised ei kirjelda pildi analüüsil määratavat klassi piisavalt hästi. Paremad tulemused on saadud kasutades puistu tasemel mõõtmisi (Mäkelä ja Pekkarinen 2004).

1.5 LiDAR (*Light Detection And Ranging*)


1.5.1 Ajalugu

1970ndatel hakkas NASA tööd tegema laseriga töötava kaugseire osas. Selle ettevõtmise eesmärk oli atmosfääri, maailmamerede ja metsade topograafiline kaardistamine (Bcc Research 2018). Seda tüüpi kaugseire on tihedalt seotud geograafilise asukohamääramisega ja kuni aastani 2000 olid GPS süsteemid küll avalikult kättesaadavad, kuid strateegilistel kaalutlustel GPS signaali segati, mis ei andnud selle kasutajatele täpseid andmeid. Peale millenniumit on LiDARi tehnoloogia teinud läbi suure arengu ning tänapäevased seadmed annavad väga täpseid tulemusi.

1.5.2 Ülevaade

LiDAR (*Light Detection And Ranging*) on kaugseire meetod, mis kasutab andmestiku kogumiseks laserimpulsse. LiDAR-skanneerimise kohta kasutatakse ka terminit ALS (*Aerial Laser Scanning*). ALS ehk õhust tehtav laserskaneerimine on tegevus, mida tehakse kasutades LiDARit. Laserimpulsid saadetakse seadmest vaadeldava objekti poole ning sealt hajuvad nad seadme detektori poole tagasi ning seadmesse salvestub peegeldunud punkti täpne ruumiline asukoht (WebCitation 2013). Peegeldunud punkti täpse asukoha saab kätte vaid sel juhul, kui on määratletud lennuki ja seega LiDARi detektori täpne asukoht, asend ja sõidusuund – selleks kasutatakse GNSS ja IMU süsteemi (joonis 5; Lang et al. 2012). GNSS (*Global Navigation Satellite System*) on ülemaailmne, erinevaid satelliidisüsteeme hõlmav, navigatsioonisüsteem. GNSS-i alla kuuluvad USA NAVSTAR GPS süsteem, Euroopa Liidu Galileo süsteem, Venemaa GLONASS süsteem ning Hiina Beidou navigatsioonisüsteem (European Global Navigation... 2017). IMU (*Inertial Measurement Unit*) mõõdab objektile mõjuvaid jõude. LiDAR kaugseirel mõõdab IMU lennukie mõjuvaid jõude, lennuki asendit ning salvestab selle info. IMU annab LiDARi andmestikule parandusi, mis tulenevad lennuki asendist (IMU). Metsanduslikus kaugseires tehakse LiDARi andmete kogumist kõrgusel 500(200) m kuni 3000 m (White et al. 2016). Võimekamate LiDAR süsteemide puhul nagu Riegl VQ-1560i on võimalik teha

üle 1,3 miljoni mõõtmise sekundis, mis erinevatelt kõrgustel mõõtmisel annab erineva tihedusega punktipilvi (RIEGL VQ-1560i 2018). Kogunenud punktipilvedest saab kokku panna kolmemõõtmelise kujutise, mis annab üsna täpse iseloomustuse metsa võrastiku liitusest, puistu kõrgusest ja kautselt ka puidu mahust. Takseertunnuste hindamiseks kasutatakse punktipilvedest saadud peegelduste kõrgusjaotust, mis on korrelatsioonis puistu võrastikuga (Lang et al. 2012).



Joonis 5. LiDARiga tehtud kaugseire põhimõte – samal ajal kui sensor impulsse välja saadab ja vastu võtab, salvestatakse info lennuki täpse geograafilise asukoha kohta ning sõidu asendi ja suuna kohta. Neid andmeid töötlevad vastavalt GNSS süsteem ja lennuki pardal olev IMU süsteem (Yellowscan-lidar 2019; White et al. 2016).

Järgnevalt võtaks vaatluse alla kolm teadustööd, milles kasutati LiDARit, et anda ülevaade mõõtmiskõrguse ja punktipilve tiheduse kohta. Esimeses kasutati 2008. aastal Leica ALS50-II süsteemi Aegviidu katseala takseerandmete hindamiseks. Leica ALS50-II skanneriga mõõtmiskõrgusel 2400 m saadi lennuribal keskmiseks punktutiheduseks 1-1,2 p/m². Kuna punktutihedus oli niivõrd väike, siis rakendati sellele puistu tasemel üldine mudel (Lang et al. 2012). Teises teadustöös kasutati 2016. aastal Riegl LMS-Q680i skannerit puistu liigilise koosseisu hindamiseks. Riegl LMS-Q680i skanneriga, 300 m kõrguselt, saadi lennuribal keskmiseks punktide arvuks ruutmeetrile 70 p/ m² (Shi et al. 2018). 2017. aastal hindasid Lang et al. (2017) Järvelja puistuid, eesmärgiks kõrguskasvu hindamine. Selleks kasutati Maaameti mõõtmisi, mis tehti skanneriga Riegl VQ-1560i.

Mõõdeti kõrguselt 300 m ja saadi tulemuseks 161 p/m². Punktipilvede tihedused on otseses seoses ka instrumentide arenguga – Riegl VQ-1560i oli antud skanneritest kõige uuem ja parimate tehniliste omadustega. Tabelis 2. on esitatud eelnimetatud skannerite tehnilise info.

Tabel 2. Aerolidarite Leica ALS50-II, Riegl LMS-Q680i ja Riegl VQ-1560i tehnilised parameetrid (Riegl LMS-Q680i 2012; Riegl VQ-1560i 2018; LIDAR Leica ALS50-II 2012).

Tunnus	Leica ALS50-II	Riegl LMS-Q680i	Riegl VQ-1560i
Väljalaske aasta	2006	2012	2017
Maksimaalne töökõrgus (m)	5000	5000	4700
Maksimaalne efektiivse impulsi sagedus (kHz)	150	266	2000
Skanneerimise muster	Sinusoidaalne	Paralleelsed jooned	Paralleelsed kanalis
Maksimaalne skanneerimisnurk	75	60	60
Maksimaalne pulsisagedus (Hz)	150 000	400 000	2000000
Kõrguse täpsus (mm)	70-140	20	20
Laseri lainepikkus (nm)	1064	1550	1064

1.5.3 Puistu liigilise koosseisu määramine

Liigilise koosseisu määramise esimene ülesanne on anda hinnang kas tegu on lehtpuuga või okaspuuga. Kosmosepildi töötlemisel tulevad nende kahe erinevused välja lähis-infrapuna-piirkonnas. LiDARiga okaspuu ja lehtpuu hindamisel on parim meetod teha mitu vaatlust, millest üks siis, kui lehed on puul, ning teine, kui lehed on langenud (Fassnacht et al. 2016). See annab ülevaate okaspuude ning lehtpuude osakaalust kuna lehes puult tekib palju rohkem impulsside tagasihajuvust kui lehtedeta puult ning okaspuude võra tabavate impulsside tagasihajuvus on olenemata aastaajast sama. Enamikest selle küsimusega tegelenud teadustöödest tuleb siiski välja, et LiDAR andmestikku kasutades ei ole võimalik võrastiku struktuuri järgi täpset liigilise koosseisu hinnangut anda. Rootsis tehti uurimus, kus LiDAR instrumendina kasutati Optech Titan X-i lennukõrgusel 400 m ning eesmärgiks oli tuvastada parimad tunnused liigilise koosseisu prognoosimiseks. Klassifitseerimise meetodiks kasutati lineaarset diskrimineerivat analüüsi ning takseerandmed saadi 179 üksikpuu mõõtmisel, mille seas oli 10 erinevat liiki. Ainult LiDARi andmestikust saadud puistu struktuuri järgi oli hinnangu täpsus võrreldes puistust saadud mõõtmistega vaid 43%. Kui sellele lisaks kasutati “leave-one-out” ristvalideerimise meetodit ning LiDARi signaalide intensiivsust, saadi hinnangu isegi kuni 76,5% ning selle juures olid hariliku kuuse ning hariliku männi hinnangud ligi 100% (Axelsson et al. 2018).

1.5.4 Puistu kõrguse ja tüvemahu määramine

LiDAR süsteemiga puistu kõrguse hindamine on üks täpsemaid meetodeid, mida metsade kaugseires kasutada saab. Kuna LiDARI punktipilvest saab välja tuua nii maapinnalt- kui ka puude võradelt tagasi hajunud laserimpulside asukohapunktid, siis on võimalik leida punktide kõrgused maapinna suhtes ja punktide vertikaalse asukoha järgi. Kasutades kõrgusjaotuse protsentiile, on võimalik arvutada puude kõrgused. Eestis on selliseid katseid tehtud mitmeid.

2017. aastal võrdlesid Lang et al. (2017) Järvselja puistute kõrguskasvu diferentsmudeli ning LiDAR andmestiku vahel. Ette võetud ajaline periood oli 2009-2017. 2009. aastal tehtud LiDAR mõõtmised skanneriga Leica ALS50-II, kõrguselt 500 m ning 2017. aasta mõõtmised Riegl VQ-1560i skanneriga ja kõrguselt 300 m. LiDAR andmestiku töötlemiseks kasutati esimeste peegelduste 80,- 90,- 95,- ja 99- protsentiile. Tulemuseks leiti, et kõik protsentiilid peale 80-protsentiili, hindasid puistu kõrguskasvu suuremaks kui diferentsmudel. Järeldati, et mitukümmend aastat tagasi välja töötatud diferentsmudelit peab uuendama, kuna puistute kõrguskasv on muutunud.

Eestis on uurimusi läbi viidud ka kontrollimaks metsade tagavara, võttes aluseks erinevad statistilised allikad. Arumäe ja Lang (2016) viisid Aegviidu katsealal läbi uurimuse, kus kõrvutati metsade tagavara andmed Metsaregistrist, SMI-st ja LiDAR andmestikust. Tuli välja, et LiDAR andmestikuga mõõdetud ja SMI käigus mõõdetud tagavarad kattusid suures osas, kuid Metsaregistri tagavarad olid süstemaatiliselt alahinnatud. Taolised katsed annavad sisendeid statistiliste süsteemide üle vaatamiseks ning parandamiseks.

Puistute tüvemahtude hindamise meetodeid on mitmeid – ülepinnalise mõõtmisega ning üksikpuu meetodil. Wigginsa et al. (2019) tehtud katse käigus selgitati välja, et kasutades punktipilvede töötlemise tarkvara FUSION laiendit TreeSeg üksikpuude tuvastamisel, mängis suurt rolli minimaalse kõrgusega puu tuvastamine. Ilma minimaalse kõrguse rakendamiseta oli üksikpuude tuvastuste arv metsast loetud puudega 36%. Kui minimaalne kõrgus, millelt puid tuvastati tõsteti 15 meetrini, siis paranes LiDARI andmestiku ja metsas mõõdetud puude arvu seos 91%-ni.

1.5.5 Biomassi määramine

Puistu biomassi moodustavad puu lehed (okkad), viljad, puu tüvi, känd ning juured. Biomassi saab arvutada enamasti rinnasdiameetri ja puu kõrguse mudeli läbi (Lang et al. 2016).

Üha aktuaalsemaks muutub metsade kaugseire arengus metsade biomassi hindamine. Teades biomassi hinnanguid, on võimalik teada saada süsiniku sidumise suurusjärke. Süsinikdioksiid on äärmiselt oluline maailma kliimat mõjutav tegur. Inimtegevuse põhjustatud, järjest suurenev õhu süsihappegaasi sisaldus, mängib suurt rolli kliimamuutustes, mis on kiirenenud just viimase saja aasta jooksul (NASA 2019c). Nende muutuste pidurdamiseks on üheks paremaks lahenduseks süsiniku sidumine puittaimestikku.

Arumäe ja Lang (2016) hindasid Aegviidu katsealal koos tüvemahtude andmete prognoosimisega ka Eesti metsade süsinikuvarusid hektari kohta. Statistilise Metsainventuur 2016 tüvemahtude ja metsapindala järgi oli Eesti puistute keskmine biomassi seotud süsiniku hinnang 76 t C/ha. Sidudes Aegviidu katsealal olevate puistute biomassi seotud süsiniku kaardi metsaregistri andmestikuga, saadi Eesti puistute keskmiseks biomassi seotud süsiniku hinnanguks 70 t C/ha, mis ei erinenud väga palju SMI statistikast.

Kasutades Aastaraamat Mets 2017 statistikat ning võttes Eesti metsade pindalaks 2,3 miljonit hektarit, on võimalik arvutada, kui palju salvestub süsinikku puittaimestikku ning milline on maapealse biomassi osa, mille moodustavad puutüved (metsade tagavara) (tabel 3; Aastaraamat Mets... 2018).

Tabel 3. Aastaraamat Mets 2017 statistika põhjal tehtud arvutused, mis iseloomustavad puittaimestiku maapealse osa biomassi ning selles sisalduvat süsinikuvaru.

Tunnus	Väärtus
Puistu 1 ha keskmine aastane juurdekasv (m^3/ha)	5.5
Keskmine tüvemaht (ha/m^3)	209
Puidu keskmine tihedus (kg/m^3)	500
Keskmine süsiniku sisaldus 1 kg puidus (kg)	0.5
Eesti metsade keskmine aastane juurdekasv kokku (mln m^3)	12.7
Aasta jooksul seotud süsinik Eesti metsades (mln t)	3.2
Eesti metsade tagavara (mln m^3)	480.7

1.6 Kaugseirepildid ja LiDAR andmestik kombineerituna


Erinevad teadustööd on tõestanud, et aero- ja kosmosepildid ning ALS (*Aerial Laser Scanning*) andmestik sobivad erinevate takseertunnuste hindamiseks. ALS on lennukilt tehtav laserskaneerimine, milleks kasutatakse LiDARit. Näiteks sobivad satelliitpildid ja aerofotod paremini puistu liigilise koosseisu hindamiseks ning ALS andmestik annab parema puistu kõrguse ja tüvemahu hinnangu. Avastatud on, et mõlemat meetodit koos kasutades, täiendavad need üksteist ning annavad veel täpsemaid hinnanguid.

2018. aastal Saksamaal tehtud uurimuse käigus püüti välja selgitada, kui täpse hinnangu annab hüperspektraalne andmestiku ja ALS andmestiku kombineerimine. Selleks kasutati lennukile kinnitatud hüperspektraalset HySpex sensorit ning Riegl LMS-Q680i LiDARit. Uuritav piirkond koosnes kahest 25 ha alast ning peamiselt kolmest peapuuliigist – harilik kuusk, harilik pöök ning euroopa nulg. Seirelennud tehti 2016. aastal. Hinnati puulehtede veesisaldust, keskmise lehe massi pindalaühikule ja lehe klorofüllitaset. Lehtede ja okaste pindala mõõdeti välitööde käigus mobiilse lehe pindala mõõteriistaga AM350. Lehtede/okaste klorofüllitaset mõõdeti klorofüllimõõteriistaga CCM300 ning lehe mass pinnaühiku kohta arvutati peale seda, kui oli mõõdetud värske lehe mass ning ahjus kuivatatud lehe mass. Ainult hüperspektraalset andmestikku kasutades, tuli hinnangu täpsuseks 69,3% ning ainult ALS andmestikku kasutades, tuli hinnang täpsusega 65,1%. Mõlemat andmestikku koos kasutades saadi aga hinnangu täpsuseks 83,7%. Uurides erinevate puuliikide biofüüsilisi tunnuseid, on võimalik neid kaugseire kaudu paremini eristada (Shi et al. 2018). Eriti tähtis on puuliikide eristamine heterogeensetes puistutes, mis moodustavad Eesti puistutest väga suure osa.

2019. aastal Kanadas avaldatud uurimuse käigus hinnati kosmosepiltide ning ALS abil lehtpuu-enamusega puistu rinnaspindala, okaspuude rinnaspindala osakaalu ja täiust ning püüti leida kõige kulutõhusam satelliitskanner. Multispektraalne andmestik valiti Landsat-5 TM, Sentinel-2A MSI ja WorldView-2 seadetes ning selle töötlemiseks kasutati juhusliku metsa regressiooni mudelit (*random forest*). ALS andmestik koguti 2009 aasta erinevatel aastaegadel, et üles võtta lehtedega puude andmed ning lehtedeta puude andmed. Selleks kasutati ALTM 3100 skannerit, kõrguselt 1500 m. Spektraalsete mudelite koostamisel andis kõige tagasihoidlikemaid tulemusi Landsat-5 TM instrumendiga tehtud kosmosepildid – määravaks sai sensori väike spektraalne,- ja ruumiline resolutsioon. Selgus, et rinnaspindala hindamiseks oli parim ALS ja WorldView-2 andmestiku kombinatsioon, mis andis determinatsioonikordajaks $R^2=0,73$. Okaspuude rinnaspindala osakaalu hindamisel andis parima tulemuse ALS ja WorldView-2 andmestik, mille hinnangu $R^2=0,90$, mis oli veidi parem ALS ja Sentinel-2A MSI andmestike kombinatsioonist ($R^2=0,88$). Täiuse hinnangul andis täpseima tulemuse ALS ja Sentinel-2A MSI andmestik ($R^2=0,67$). Sama tunnuse hindamisel andis ainult ALS andmestiku kasutamine tulemuseks $R^2=0,66$. Kuluefektiivsuse osas saavutas parima tulemuse Sentinel-2A MSI instrument, sest kuigi Sentinel-2A MSI kosmosepildid jäid hinnangute andmisel napilt alla WorldView-2 skannerile, siis oli WorldView-2 andmestiku kõrge hind see, mis sai kulutõhususe osas määravaks (Shang et al. 2018).

1.7 Aerofotograafia ja aerofotogramm-meetria

Esimesed aerofotograafilised katsetused tehti 19. sajandi keskel prantslase Gaspard-Félix Tournachon-i poolt, kes pildistas kuumaõhupalli korvist Pariisi. 19. sajandi teisel poolel eksperimenteeris aerofotograafiat veel tuulelohe külge kinnitatud kaameraga briti meteoroloogist E.D.Archibald. Praktilisema otstarbe sai aerofotograafia Esimese Maailmasõja ajal, kui seda kasutati lennukitelt vaenlase tegevuse jälgimiseks (PAPA International 2019). Tänapäeval kasutatakse aerofotosid maakasutuse uurimiseks. Aerofotosid tehakse peamiselt lennukitelt, helikopteritelt ning üha enam ka droonidelt. Kaamera on suunatud läbi lennumasina põhja otse maapinnale ning pilte tehakse lennusuunas moodustuva ribana. Stereoskoopiliste (ruumiliste) aerofotode tegemisel peavad järjestikused pildid kattuma analoog-kaamerat kasutades vähemalt 30% ulatuses (FAO 2019). Digitaalsed aérokaamerad teevad pidevaid pilte erinevate nurkade alt lennuki sõidusuunas (joonis 6). (Maaameti Geoportaal 2018). Aerofotodega puutume kokku mitmete kaardirakenduste kasutamisel. Eestis on parim aerofotode kogu Maaametil. Maaameti kodulehelt võib need leida ortofotode nime alt. Ortofotod on aerofotod, millelt on eemaldatud maapinna reljeefi tõttu tekkinud moonutused. Üksikute ortofotode kokkumonteerimisel saadakse ortofotokaarte, mis katavad suuri alasid (Maaameti Geoportaal 2018).



Joonis 6. Aerofotograafia käigus salvestatavad multispektraalsed kanalid eesvaates, allavates ning tahavaates. Kogutakse *red*, *green*, *blue* ja lähiiinfrapuna spektrivahemikke infot (Maaameti Geoportaal 2017).

DAP ehk digitaalne aerofotogramm-meetria kujutab endas aeropiltidelt mõõtmiste tegemist. 19. sajandi keskel kasutati fotogrammeetriat kuumaõhupallidelt kaartide loomiseks ning vahekauguste määramiseks. Stereofotogrammeetrias kasutatakse kahte või enam kaamerat, mis koostöös suudavad anda pildile kolmemõõtmelise referentsi ning seeläbi luua kolmemõõtmelisi pilte (Wikipedia 2019b). Kui aerofotode andmestik on olemas, siis antakse tehtud kattuvatele piltidele automaatselt ankrupunktid, kohtadele mis paistavad pildilt kõige paremini välja. Seejärel aeropiltide andmestik seotakse koos ankrupunktidega ning selle tulemusel saadakse kolmemõõtmeline andmestik, kus ankrupunktidest moodustub punktipilv (Goodbody et al. 2019). Kuna DAP meetodil saab iseloomustada puistut sarnasel meetodil nagu ALS-ga, siis võrdlesid Noordermeer et al. (2019) nende instrumentide võimekust kirjeldamaks võrade kõrgus,- ning tihedusparameetreid. Uurimuse tulemused kinnitasid, et DAP andmestiku töötlusel saadud punktipilv kirjeldas ainult võra pealmist osa ja ALS kirjeldas nii võra pealmist osa kuni maapinnani ulatuvat osa. Seega töötab DAP paremini puistu kõrgusandmete hindamiseks ning ALS paremini puuvõrade,- alusmetsa ja maapinna kirjeldamisel.

1.8 Kaugseire kasutamine takseerimisel Eestis

1.8.1 Eesmärgid

Täpsete andmete olemasolu metsaressursside ja ökosüsteemide hindamisel tagab jätkusuutliku metsade majandamise annab hea baasinfo tulevaste metsakasvatustlike võtete kasutamisele. Üha kasvava puidu nõudlusega ühiskond vajab aina täpsemaid metsi kirjeldavaid andmeid ning moodne seiretehnika annab selleks hea võimaluse. Siinkohal ei piisa kindlasti ainult heast tehnikast. Metsandusliku kaugseire abil saadud hinnangud on põhjaliku andmetöötluse tulemus.

Metsanduse arengukava aastani 2030 (Metsanduse Arengukava... 2019) sõnastab üld-eesmäärke nii:

“Metsade kasutamine on võimalikult mitmekülgne, vastab ühiskonna ootustele ja vajadustele, aitab leevendada kliimamuutusi ja nendega kohaneda ning tagab sotsiaalselt tasakaalustatud elu- ja majanduskeskkonna ning metsaökosüsteemide soodsa seisundi.”

Kliimamuutuste osa seostub puistute biomassi hindamise,- ja süsinikuvarude määramisega, mille osas on kaugseiret kasutatud juba ammu. Soodne majanduskeskkond,- ja metsaökosüsteemid viitavad vastavalt metsaressursi mõõtmisele ning ökosüsteemide seirele, mis moodustavad samuti suure osa metsandusliku kaugseirega tehtavatest hinnangutest. Kuna metsanduslik kaugseire areneb pidevalt ning saab enam praktilisi rakendusi, siis peaks metsataksaatorite töö eesmärgiks saama looduses üha täpsemate takseerandmete üles märkimine ning keskendumine puistutele kus metsamajandamine on prioriteet (Lang et al. 2012).

1.8.2 Hetkeseis

Metsapoliitika tegemine ja metsamajandusliku tegevuse planeerimine vajavad erineval skaalal inventeerimisandmeid. Eestis kogutakse üleriigilist metsade andmeid läbi SMI (Statistiline Metsainventeerimine). SMI käigus kasutatakse ülepinnalist inventeerimist alalistel ja ajutistel ringproovitükkidel (Keskkonnaagentuur 2018a). Erametsades tehakse eraldise kaupa takseerimist, mis annab eraldise omanikule info metsamajandamiseks. Mõlema variandi puhul kasutatakse töös kaugseire andmeid (Lang et al. 2018).

Kaugseire leiab kasutust väga erinevate metsanduslike hinnangute andmisel. Eestis on see rakendust leidnud näiteks liigilise koosseisu kaardikihi loomisel, mille käigus said hinnangu ka varem takseerimata metsa-alad (Lang et al. 2018). Hinnanguid on antud kindlate puistute biomassile, mille tulemusel loodi seotud süsiniku kaart (Lang et al. 2016). Metsade majandamisel on oluline hinnata metsade tagavara ning ka selles vallas on kaugseire Eestis palju kasutust leidnud. Tamm ja Remm (2009) andsid Aegviidu katsealal hinnanguid puistute liigilisele koosseisule ja tagavarale, kasutades satelliidipilte, ortopilte ja masinõpet. ALS andmestikuga on puistute tagavara hinnanud Arumäe ja Lang (2016). Erinevates riikides tehtud uurimused näitavad, et metsade tagavara hindamisel annab täpsemaid tulemusi ALS-i andmestik, võrreldes satelliidipiltidega. Põhjuseks võib tuua selle, et satelliidipiltide töötlemisel ei teki näiteks metsa tagavara hinnates uut andmehulka, vaid olemasolevale andmestikule (spektraalinfo) omistatakse teise andmestiku (takseerkirjeldus) väärtused. Kui liigilise koosseisu hindamisel on erinevates lainevahemikes üsna selgelt eristuvad erinevad puuliigid, siis tagavara hindamisel nii selget korrelatsiooni ei teki, kuna metsa tagavara ei eristu olenevalt vaadeldavast lainevahemikust. LiDAR andmestik on selles osas erinev, sest sisaldab reaalseid ruumilisi andmeid – punktiparve signaale, millele saab anda füüsilised mõõtmed.

1.8.3 Tulevik

Tehnoloogilisest küljest oodatakse ikka seadmete arengut, mis tagavad kaugseire hinnangute käigus täpsemate sisendandmete kättesaadavuse. Hetkel on vabakasutuses näiteks selliste multispektraalsete sensorite andmestik nagu Sentinel-2 MSI ja Landsat-8 OLI. Selle kõrval opereerivad ka tulunduseesmärgiga satelliidipiltide tootvad ettevõtted nagu Satellite Imaging Corporation, mille VHR (*Very High Resolution*) satelliidipildid teevad kuni 0,31 m pankromaatilise ruumilise resolutsiooniga pilte ning 1,24 m spektraalse resolutsiooniga pilte (Satellite Imaging Corporation 2019). Suure tõenäosusega muutub kõrge resolutsiooniga satelliitandmestik tulevikus ka tasuta kättesaadavaks ning seeläbi leiab laiemat pinda ka metsandusliku kaugseire rakendamine (Mairota et al. 2015). ALS tehnoloogia suudab anda välja järjest rohkem impulsse ning seega pakub ta üha tihedamaid punkt pilvi. On näha ka trendi, mille käigus ehitatakse LiDAR sensoreid UAV-le (*Unmanned Aerial Vehicle*) ehk mehitamata õhusõidukitele. Kõige suurema potentsiaaliga UAV-ks peetakse droone ning juba ongi päris mitmeid ettevõtteid kellele on LiDARiga varustatud UAV-d põhiliseks tooteartikliks (Yellowscan-lidar 2019).

Metsamajandusliku kaugseirega seostuvad põhiliselt vertikaalse suunaga tehtud seired. Kosmosepiltide ja ALS-i kõrval kasutatakse järjest enam LiDAR seire liiki, mille seire suund on rohkem horisontaalne, kui vertikaalne – TLS. TLS ehk *Terrestrial Laser Scanning* kujutab endast maapealt tehtud seiret. Selle meetodiga saab vaadata näiteks metsade sisse, andes sellega metsanduslikule kaugseirele uue dimensiooni. Kuigi TLS-i kasutamist metsanduses on uuritud juba pikalt, siis ei ole see meetod veel suurt rakendust leidnud. Siiski on lootust, et TLS ja ALS koos kombineerides saaks luua täpsemaid mudeleid puistute kirjeldamisel. TLS on andnud positiivseid märke puistu rinnasdiameetri ja biomassi hindamisel (White et al. 2016).

2 ARUTELU

Nagu suur osa tänapäeval kasutatavast tehnikast, on metsamajanduslikuks kaugseireks kasutatavad seadmed välja kasvanud sõja,- ning kosmose tehnikast. Aerofotod said oluliseks instrumendiks Esimeses Maailmasõjas vaenlase tagala jälgimisel (Wikipedia 2019c). Ka aktiivne kaugseire sai alguse spetsiaalse militaartehnika loomisega, kui tekkis vajadus kaugseire järgi, mis ei oleks oluliselt mõjutatud pilvkattest – selle tulemuseks oli radari antenni kaudu välja saadetud mikrolained, mis hajuvad maapinnalt tagasi erineva sagedusega – oleneb materjalist, millelt nad peegeldusid (Engineering and Technology... 2009). Vabakasutusele hakati satelliidipilte tegema 1980ndatel, kui NASA saatis orbiidile Landsat-5 TM multispektraalse sensori ning Prantsusmaa, Belgia ja Rootsi ühisprojektina satelliidile SPOT-1 paigaldatud multispektraalse sensori HRV (NASA 2013.; European Space Agency 2019a). Sealt sai suurema tõuke ka teadustegevuseks kasutatav kaugseire, seal hulgas metsamajanduslik kaugseire. 1970ndatel töötati NASA poolt välja ka satelliitseirest erinev seire meetod – laserskanneerimine. Laserskanneerimise algne eesmärk oli atmosfääri, maailmamerede ja metsade topograafiline kaardistamine. Tänapäeval kasutatakse lidarskanneri kogutavat metsade andmestikku väga paljudes teadustöös (Fassnacht et al. 2016). Lidarmõõtmisel saadavaid andmeid eelistatakse puistu takseertunnuste nagu võrade kõrgus, liitus ning tihedus, prognoosimiseks. Käesoleval kümnendil on metsamajanduslikus satelliitkaugseires palju kasutatud vabavarana kättesaadavat Landsat-8 OLI ja Sentinel-2 MSI andmekogusid. OLI ja MSI andmestikku on metsandusliku uurimuse käigus võrreldud ka hüperspektraalse sensori WorldView-2 tasuliste andmekogude piltidega. Kombineerides nimetatud satelliitsensorite andmestikke lidarskanneerimisega tõdeti, et okas- ja lehtpuude rinnaspindala ning täiuse prognoosimisel ei olnud suurt vahet lidarskanneri andmestiku ja Sentinel-2 MSI andmestiku ning lidarskanneri andmestiku ja WorldView-2 andmestiku determinatsioonikordajate vahel (Shang et al. 2018).

Erinevate puistu takseertunnuste hindamiseks sobivad erinevad kaugseire meetodid. Näiteks on mitmetest teadustööst välja tulnud, et kui võrrelda ainult LiDAR andmestikul või ainult satelliitpiltide andmestikul tehtavaid puistute liigilise koosseisu prognoose, siis paremaid tulemusi annab satelliitpiltide andmestik (Lang et al. 2018; Shi et al. 2018). Kuid kõige paremaid liigilise koosseisu prognoose annab satelliitidelt või lennukilt kogutud spektraalinfo ja LiDAR andmestiku koos kasutamine (Shi et al. 2018).

Puistute ruumiliste andmete, nagu võra kõrgus ja suurus, mõõtmisel lidarskanneriga, saab teha võrdlemisi täpseid prognoose puistu keskmise kõrguse ja tüvemahu kohta. (Lang et al. 2017; Arumäe ja Lang 2016). Tüvemahu kaudu saab hinnata ka puistute biomassis seotud süsinikku. Statistilise Metsainventuuri 2016 hinnangul on Eestis puistutes keskmiselt biomassi seotud süsinikku 76 t C/ha. Aegviidus LiDAR kaugseirega tehtud tüvemahtude ja biomassi hinnangute prognoosimise käigus saadi Eesti keskmiseks puistutes seotud süsiniku suurusjärguks 70 t C/ha, mis on üsna lähedal SMI andmetele (Lang et al. 2016).

Kaugseire tehnoloogia ja andmestik muutub iga aastaga järjest täpsemaks ning kättesaadavamaks. Seetõttu on võimalik ka kaugseiret rohkem metsamajanduslikes planeeringutes rakendada. Kvaliteetsed peavad olema eelkõige inventeerimisandmed, mida kasutatakse mudelite loomiseks ja algoritmide õppeks (Lang et al. 2011).

3 KOKKUVÕTE

Antud lõputöö annab ülevaate metsade kaugseire tehnikast, meetoditest ning rakendamisest metsakorralduslike tööde tegemisel. Selleks kasutati teadustöid nii välismaalt, kui ka Eestist. Kaugseire-teemalised teadustööd annavad hea ettekujutluse metsamajanduslikest küsimustest, mis on aktuaalsed Eestis ning mujal maailmas. Mitmete teadustööde eesmärgid kattusid, seega oli võimalik võrrelda uurimuseks kasutatavaid võtteid ning tehnikat. Suurem osa uurimuste tulemusi on universaalsed ka teistes riikides kasutamiseks. Töö üks põhieesmärke oli välja selgitada kuidas oleks võimalik kaugseiret metsade takseerimisel Eestis rakendada. Võrreldes Eestis ning välismaal tehtud uurimistöid, selgus et metsamajanduslikku kaugseiret on Eestis rakendatud juba väga erinevate probleemide lahendamiseks ning metsade kaugseire Eestis ei jää tehnoloogiliselt ega teaduslikult alla välismaal rakendust leidnud kaugseirele. Lisaks põhjalikule teadustööle kaugseire alal, on metsade kaugseire rakendamisel suureks abiks riiklikud institutsioonid nagu Keskkonnaamet, Keskkonnaagentuur ja Maaamet. Maaameti kaugseirega tehtavad mõõtmised on koos ja SMI andmetega väga heaks infoallikaks metsandusalastele teadustöödele. Just uuenduslikud teadustööd annavad tõuke metsamajanduliku kaugseire rakendamisele ka metsade takseerimisel.

4 KASUTATUD KIRJANDUS

- Aastaraamat Mets 2017 (2018).
https://www.keskkonnaagentuur.ee/sites/default/files/01_metsavarud.pdf (26.05.2019)
- Altman, N.S. (1992). - An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression - *The American Statistician*. Vol. 46, No. 3, pp. 175-185.
- Arumäe, T., Lang, M. (2016). Aerolidarilt puistu tüvemahu hindamise mudelid ning võrdlus takseeritud tagavaraga - *Metsanduslikud Uurimused*. Vol. 64, pp. 5–16.
- Astola, H., Häme, T., Sirro, L., Molinier, M., Kilpi, J. (2019). Comparison of Sentinel-2 and Landsat 8 imagery for forest variable prediction in boreal region - *Remote Sensing of Environment*. Vol. 223, pp. 257-273.
- Axelsson, A., Lindberg, E., Olsson, H. (2018). Exploring Multispectral ALS Data for Tree Species Classification - *Remote Sensing*. Vol. 10, No 2, pp. 183.
- Bcc Research (2018). Brief History of LiDAR, Its Evolution and Market Definition [veebileht] <http://blog.bccresearch.com/brief-history-of-lidar-evolution-and-market-definition> (26.05.2019)
- Centre for Remote Imaging, Sensing and Processing (2001a). Microwave Remote Sensing [veebileht] <https://crisp.nus.edu.sg/~research/tutorial/mw.htm> (24.05.2019)
- Centre for Remote Imaging, Sensing and Processing (2001b). Optical Remote Sensing [veebileht] <https://crisp.nus.edu.sg/~research/tutorial/optical.htm> (26.05.2019)
- Daniel, O. (2001). Toim. Veljo Runnel. Mets ja metsandus Eestis. Tartu: Ilmamaa 229 lk.
- Eesti Metsavarud (2008). Keskkonnaministeerium.
https://www.envir.ee/sites/default/files/elfinder/article_files/eestimetsavarud_1.pdf (11.05.2019)
- Engineering and Technology History Wiki (2009). Synthetic Aperture Radar. [veebileht] https://ethw.org/Synthetic_Aperture_Radar (21.05.2019)
- European Global Navigation Satellite Systems Agency (2017). What is GNSS? [veebileht] <https://www.gsa.europa.eu/european-gnss/what-gnss> (21.05.2019)

- European Space Agency (2014). Vegetation mapping. [veebileht] http://www.esa.int/SPECIALS/Eduspace_EN/SEM6SQ3Z2OF_0.html (11.05.2019)
- European Space Agency (2019a). 3rd Party Missions. [veebileht] <https://earth.esa.int/web/guest/missions/3rd-party-missions/current-missions/spot-1> (26.05.2019)
- European Space Agency (2019b). Sentinel-2 Overview. [veebileht] <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/overview> (21.05.2019)
- FAO (2019). Aerial photography [veebileht] <http://www.fao.org/3/x5345e/x5345e04.htm> (11.05.2019)
- Fassnacht, F.E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L.T., Straub, C., Ghosh, A. (2016). Review of studies on tree species classification from remotely sensed data - *Remote Sensing of Environment*. Vol. 186, pp. 64-87.
- Federal Institute for Geosciences and Natural Resources (2019). Radar remote sensing. [veebileht] https://www.bgr.bund.de/EN/Themen/GG_Fernerkundung/Radarfernerkundung/radarfernerkundung_node_en.html (11.05.2019)
- Gisgeography (2019). 100 Earth Shattering Remote Sensing Applications & Uses. [e-ajakiri] <https://gisgeography.com/100-earth-remote-sensing-applications-uses/> (10.02.2019)
- Goodbody, T.R.H., Coops, N.C., White, J.C. (2019). Digital Aerial Photogrammetry for Updating Area-Based Forest Inventories: A Review of Opportunities, Challenges, and Future Directions - *Current Forestry Reports*. Vol. 5, No 2, pp 55–75.
- Kalle, R. (2018). Eestis on metsa vähem kui sajand tagasi? – *Õhtuleht*. [e-ajakiri] <https://www.oh tuleht.ee/855177/raivo-kalle-eestis-on-metsa-vahem-kui-sajand-tagasi>
- Katila, M., Tomppo, E. (2001). Selecting estimation parameters for the Finnish multisource National Forest Inventory - *Remote Sensing of Environment*. Vol. 76, No 1, pp. 16-32.
- Keskkonnaagentuur (2018a). Metsade inventeerimise alused [veebileht] <https://www.keskkonnaagentuur.ee/et/uudised/metsade-inventeerimise-alused> (20.05.2019)
- Keskkonnaagentuur (2018b). Tunnustatud metsakorraldajad (metsakorraldaja eksami ja katsetöö sooritanud isikud) [veebileht] <https://www.keskkonnaagentuur.ee/et/metsakorraldajad> (20.05.2019)
- Lang, M., Kardakov, A., Lükk, T., Arumäe, T., Korjus, H. (2011). - Metsanduslik andmehõive ajas, ruumis ja pildis – *Eesti Mets* No. 4.

- Lang, M., Arumäe, T., Anniste, J. (2012). Lennukilidari ja spektraalse kaugseireandmestiku kasutamine metsa peamiste takseertunnuste hindamiseks Aegviidu katsealal - *Metsanduslikud uurimused*. Vol. 56, pp. 27–41.
- Lang, Mait; Arumäe, Tauri (2014). Kaugseire praktilistes metsanduslikes rakendustes Eestis. Toim. Anne Aan, Kirke Narusk. *Kaugseire Eestis* pp. 128–137. Tallinn: Keskkonnaagentuur.
- Lang, M., Arumäe, T., Nikopensius, M. (2016). Puistute biomassi ja süsiniku hulga hindamine kaugseire abil. Toim. U. Peterson, T. Lillemaa. - *Kaugseire Eestis* pp. 58–66.
- Lang, M., Arumäe, T., Laarmann, D., Kiviste, A. (2017). Puistute kõrguskasvu muutuse hindamine - *Metsanduslikud Uurimused*. Vol. 67, pp. 5–16.
- Lang, M., Kaha, M., Laarmann, D., Sims, A. (2018). Construction of tree species composition map of Estonia using multispectral satellite images, soil map and a random forest algorithm - *Metsanduslikud Uurimused*. Vol. 68, pp. 5–24.
- LIDAR Leica ASL50-II (2012). Maaameti Geoportaal. https://geoportaal.maaamet.ee/docs/2012_LIDAR.pdf (08.05.2019)
- Maaameti Geoportaal (2017). Aerokaamera- Leica ADS100-SH100. [veebileht] <https://geoportaal.maaamet.ee/est/Andmed-ja-kaardid/Ortofotod/Tootmislugu/Aerokaamera-Leica-ADS100-SH100-p542.html> (20.05.2019)
- Maaameti Geoportaal (2018). Tootmislugu. [veebileht] <https://geoportaal.maaamet.ee/est/Andmed-ja-kaardid/Ortofotod/Tootmislugu-p189.html> (20.05.2019)
- Mairota, P., Cafarelli, B., Didham, R.K., Lovergine, F.P., Lucas, R.M., Nagendra, H., Rocchini, D., Tarantino, C. (2015). Challenges and opportunities in harnessing satellite remote-sensing for biodiversity monitoring - *Ecological Informatics*. Vol. 30, pp. 207-214.
- Meikar, T. (2018). Toim. Viio Aitsum, Sirje Nilbe. *Eesti metsanduse 100 aastat*. Tallinn: Post Factum 192 lk.
- Metsanduse Arengukava aastani 2030 koostamise ettepanek (2019). https://www.envir.ee/sites/default/files/metsanduse_arengukava_aastani_2030_koostamise_ettepanek_21_12_2018.pdf (08.05.2019)
- Metsa korraldamise juhend (2018). (Vastu võetud 16.01.2009 nr 2, Viimati jõustunud 26.01.2009). – *Riigi Teataja*. <https://www.riigiteataja.ee/akt/13124148?leiaKehtiv> (31.08.2018)
- Mäkelä, H., Pekkarinen, A. (2004). Estimation of forest stand volumes by Landsat TM imagery and stand-level field-inventory data - *Forest Ecology and Management*. Vol. 196, No 2–3, pp. 245-255.

- NASA (2013). Landsat 5 [veebileht] https://www.nasa.gov/mission_pages/landsat/news/landsat5-guinness.html (16.05.2019)
- NASA (2019a). Jet Propulsion Laboratory. Aviris. [veebileht] <https://aviris.jpl.nasa.gov> (19.05.2019)
- NASA (2019b). Landsat 8 Overview. [veebileht] <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview/> (08.05.2019)
- NASA (2019c). Climate Change: How Do We Know? [veebileht] <https://climate.nasa.gov/evidence/> (19.05.2019)
- Nilson, T. (1994). Metsade kaugseire alused. Tartu: Metsaamet. 160 lk.
- Noordermeer, L., Bollandås, O.M., Ørka, H.O., Næsset, E., Gobakken, T. (2019). Comparing the accuracies of forest attributes predicted from airborne laser scanning and digital aerial photogrammetry in operational forest inventories - *Remote Sensing of Environment*. Vol. 226, pp. 26-37.
- PAPA International (2019). History of aerial photography [veebileht] https://papa.clubexpress.com/content.aspx?page_id=22&club_id=808138&module_id=158950&sl=1251007960 (28.05.2019)
- Pärt, E. (2008). Eesti metsavarud ajaloo tuultes – *Eesti Mets*. Nr. 4. [e-ajakiri] http://vana.loodusajakiri.ee/eesti_mets/artikkel1862_839.html (19.05.2019)
- Riegl LMS-Q680i (2012). http://www.riegl.com/uploads/tx_pxpriegldownloads/10_DataSheet_LMS-Q680i_28-09-2012_01.pdf (08.05.2019)
- Riegl VQ-1560i (2018). http://www.riegl.com/uploads/tx_pxpriegldownloads/RIEGL_VQ-1560i_infosheet_2018-10-02.pdf (26.05.2019)
- Rocchini, D., Foody, G.M., Nagendra, H., Ricotta, C., Anand, M., He, K.S., Amicih, V., Kleinschmitt, B., Forster, M., Schmidlein, S., Feilhauer, H., Ghisla, A., Metz, M., Neteler, M. (2013). Uncertainty in ecosystem mapping by remote sensing - *Computers & Geosciences*. Vol. 50, pp. 128-135.
- Sada aastat Eesti metsa lugu (2019). Koost. Triin Kusmin. Toim. Toivo Meikar, Jürgen Kusmin. Tallinn: RMK
- Satellite Imaging Corporation (2019). WorldView-3 Satellite Sensor (0.31m) [veebileht] <https://www.satimagingcorp.com/satellite-sensors/worldview-3/> (08.05.2019)

- Shang, C., Treitz, P., Caspersen, J., Jones, T. (2018). Estimation of forest structural and compositional variables using ALS data and multi-seasonal satellite imagery - *International Journal of Applied Earth Observation and Geoinformation*. Vol. 78, pp. 360-371.
- Shi, Y., Skidmore, A.K., Wang, T., Holzwarth, S., Heiden, U., Pinnel, N., Zhu, X., Heurich, M. (2018). Tree species classification using plant functional traits from LiDAR and T hyperspectral data. - *International Journal of Applied Earth Observation and Geoinformation*. Vol. 73, pp. 207-219.
- Sims, A. (2018a). Metsa inventeerimise alused – Maa Elu. [e-ajakiri] <https://maaelu.postimees.ee/4417981/metsa-inventeerimise-alused> (22.02.2018)
- Sims, A. (2018b). Keskkonnaagentuur. Metsa inventeerimise alused. <https://www.keskkonnaagentuur.ee/et/uudised/metsade-inventeerimise-alused>
- Tamm, T., Remm, K. (2009). Estimating the parameters of forest inventory using machine learning and the reduction of remote sensing features. - *International Journal of Applied Earth Observation and Geoinformation*. Vol. 11. No. 4, pp. 290-297.
- The EO-1 Hyperion Imaging Spectrometer (2019). https://eo1.gsfc.nasa.gov/new/validationReport/Technology/TRW_EO1%20Papers_Presentations/10.pdf (20.05.2019)
- U.S. Geological Survey (2017). Landsat 8. [veebileht] https://www.usgs.gov/land-resources/nli/landsat/landsat-8?qt-science_support_page_related_con=0#qt-science_support_page_related_con (16.05.2019)
- Vaus, M. (2005). Metsatakseerimine. Tallinn: Halo. 178 lk.
- WebCitation (2013). LIDAR—Light Detection and Ranging—is a remote sensing method used to examine the surface of the Earth. [veebileht] <https://www.webcitation.org/6H82i1Gfx?url=http://oceanservice.noaa.gov/facts/lidar.html> (23.05.2019)
- White, J.C., Coops, N.C., Wulder, M.A., Vastaranta, M., Hilker, T., Tompalski, P. (2016). Remote Sensing Technologies for Enhancing Forest Inventories: A Review -*Canadian Journal of Remote Sensing*. Vol. 42, No 5: Remote Sensing for Advanced Forest Inventory, pp. 619-641.
- Wiggins, H.L., Nelson, C.R., Larson, A.J., Safford, H.D. (2019). Using LiDAR to develop high-resolution reference models of forest structure and spatial pattern - *Forest Ecology and Management* Vol. 434, pp. 318-330.

- Wikipedia (2019a). Inertial measurement unit. [veebileht]
https://en.wikipedia.org/wiki/Inertial_measurement_unit (23.05.2019)
- Wikipedia (2019b). Photogrammetry [veebileht] <https://en.wikipedia.org/wiki/Photogrammetry>
(26.05.2019)
- Worman, C., McMorrow, J. (2002). Dark Peak Fieldwork. Introduction to the Landsat Thematic Mapper Image and Satellite Images. [veebileht]
http://media.humanities.manchester.ac.uk/humanities/geog_dark_peak/landsat.htm
(24.05.2019)
- Yellowscan-lidar (2019). Easy data acquisition, streamlined point cloud processing [veebileht]
<https://www.yellowscan-lidar.com/products> (23.05.2019)

**Lihtlitsents lõputöö salvestamiseks ja lõputöö üldsusele kättesaadavaks tegemiseks
(avaldamise tähtajaline piirang) ning juhendaja(te) kinnitus töö kaitsmisele lubamise
kohta**

Mina, Uku Meriloo,
sünniaeg 21/01/1990,

1. annan Eesti Maaülikoolile tasuta loa (lihtlitsentsi) enda koostatud lõputöö

KAUGSEIRE RAKENDAMINE METSA TAKSEERIMISEL EESTI OLUDES.

mille juhendaja on Mait Lang,

1.1. salvestamiseks säilitamise eesmärgil,

1.2. digiarhiivi DSpace lisamiseks ja

1.3. veebikeskkonnas üldsusele kättesaadavaks tegemiseks pärast tähtajalise piirangu
lõppemist

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.

Lõputöö autor _____

(allkiri)

Tartu, _____

(kuupäev)

Juhendaja(te) kinnitus lõputöö kaitsmisele lubamise kohta

Luban lõputöö kaitsmisele.

(juhendaja nimi ja allkiri)

(kuupäev)

(juhendaja nimi ja allkiri)

(kuupäev)

