



Karelia-ammattikorkeakoulu
Metsätalousinsinööri (AMK)

Dronekuvista tulkittujen puustotunnusten tarkkuus

Maisa Ikonen

Opinnäytetyö, huhtikuu 2023

www.karelia.fi



OPINNÄYTETYÖ
Huhtikuu 2023
Metsätalouden koulutus

Tikkarinne 9
80200 JOENSUU
+358 13 260 600

Tekijä
Maisa Ikonen

Nimeke
Dronekuvista tulkittujen puustotunnusten tarkkuus

Toimeksiantaja
AFRY

Tiivistelmä

Metsien inventoinnilla kerätään tietoa metsävaroista päätöksenteon tueksi. Miehittämättömät ilma-alukset eli dronet ovat uusimpia siihen käyttöönotettuja teknologioita. Dronekuvista muodostetaan fotogrammetrian avulla pistepilviä, joista voidaan tulkita metsikön puustotunnuksia.

Tutkimusalue sijaitsi Keski-Ruotsissa, ja siellä toteutettiin maasto- ja droneinventointi syksyllä 2022. Käsiteltäviä aineistoja olivat referenssiaineistona toimivat maastomittaukset sekä erilaiset dronekuviin pohjautuvat aineistot. Tarkoituksena oli selvittää, mihin tarkkuuteen menetelmällä päästiin. Tutkimuksen aineisto on AFRY:n prosessista välitulos, jota jatkojalostetaan vielä eteenpäin. Tulokset eivät siis kuvaa lopullisen inventointituloksen tarkkuutta.

Tarkasteltavia puustotunnuksia olivat keskitilavuus (V), pohjanpinta-ala (G), keskiläpimitta (D), keskipituus (H) ja runkoluku (N). Puustotunnusten harhat olivat pieniä, mutta RMSE:t olivat suurempia. Dronekuviin pohjautuvassa aineistossa, jossa puuhakuparametrit oli säädetty välttämään puiden lukumäärän yliarviointia, keskitilavuuden (V) suhteellinen harha oli 16 % ja suhteellinen RMSE oli 29 %. Aineistossa, johon oli maastokoealojen avulla kalibroitu lisää puita, keskitilavuuden (V) suhteellinen harha oli 4 % ja suhteellinen RMSE 31 %. Molemmissa aineistoissa kaikkien puustotunnusten regressioanalyysistä saadut selityskertoimet R^2 olivat yli 0,6.

Dronekuvien pohjalta tulkitut puustotunnukset osoittautuivat luotettaviksi ja lopputuloksissa oli samoja piirteitä aiempien tutkimusten kanssa. Parhaimmat tulokset saatiin hoidetuista ja harvoista metsistä. Eniten haasteita aiheuttivat tiheät ja hoitamattomat metsät.

Kieli
suomi

Sivuja 77

Asiasanat
dronet, fotogrammetria, kaukokartoitus, metsävarat



THESIS
Aril 2023
Degree Programme in Forestry

Tikkarinne 9
80200 JOENSUU
FINLAND
+ 358 13 260 600

Author
Maisa Ikonen

Title
The Accuracy of Forest Attributes Based on Drone Images

Commissioned by
AFRY

Abstract

Unmanned aerial vehicles (UAV) i.e., drones are one of the newest technologies in forest inventory. Drone images are processed to point clouds with photogrammetric software. The point clouds are used to estimate forest attributes.

The research area is in central Sweden, and terrain and drone inventory were carried out there in the fall of 2022. There are data based on terrain measurements and drone images. Terrain measurements act as reference data. The purpose of this thesis was to find out what accuracy was achieved with the methods. The research data is an intermediate result of AFRY's process, which will be advanced in the future. Therefore, the results do not describe the accuracy of the final inventory result.

The observed forest attributes are mean volume (V), basal area (G), mean diameter (D), mean height (H) and stem number (N). Their relative BIAS were low, but relative RMSE were higher. In the data based on drone images, the relative BIAS of the mean volume (V) was 12 % and the relative RMSE was 30 %. In the drone data with added trees, the relative BIAS of the mean volume (V) was 4 % and the relative RMSE was 31 %. Plot level regression analysis revealed adjusted R^2 values over 0.6 for all attributes in both materials.

The forest attributes proved to be reliable, and they were in line with previous studies. The best results came from managed and sparse forests. There were more challenges in unmanaged and dense forests.

Language
Finnish

Pages 77

Keywords
drone, UAV, photogrammetry, remote sensing, forest inventory

Sisältö

1	Johdanto	5
2	Kaukokartoitus metsien inventoinnissa	6
2.1	Kaukokartoitus	6
2.2	Aineistojen tulkinta	7
2.3	Ilmakuvat	8
2.3.1	Ilmakuvauslennot	8
2.3.2	Sovelluksia	9
2.4	Satelliittikuvat	10
2.4.1	Eri satelliitteja	11
2.4.2	Soveltaminen metsätaloudessa	11
2.5	Laserkeilaus	12
2.5.1	Laitteisto ja lennot	13
2.5.2	Harvapulssiaineisto	13
2.5.3	Tiheäpulssiaineisto	14
2.5.4	Sovelluksia	14
2.5.5	Metsävaratieto	17
2.6	Metsien inventointi dronella	18
2.6.1	Dronetekniikkaa	19
2.6.2	Sensorit	22
2.6.3	Dronekuvien tulkinta ja sovellukset	24
3	Tutkimuksen tausta ja tavoitteet	29
4	Aineistot	30
4.1	Maastoinventointi	30
4.2	Dronekuvaukset	33
4.3	Aineistojen analyysi	34
5	Tulokset	39
5.1	Puiden tunnistaminen koelaitoilta	39
5.1.1	Mänty-kuusisekametsä	39
5.1.2	Elävät ja kuolleet kuuset	41
5.1.3	Harvennettu männikkö	43
5.1.4	Kaksijakoinen metsä	44
5.2	Runkolukusarjat	46
5.2.1	Kaikki puulajit	46
5.2.2	Mänty	47
5.2.3	Kuusi	48
5.2.4	Lehtipuu	50
5.3	Puustotunnukset	52
5.4	Kuolleet puut	61
5.5	Päivitetty aineisto	63
5.6	Kalibrointikertoimilla lisätyt puut	66
6	Pohdinta	70
6.1	Tulosten tarkastelu	70
6.2	Luotettavuus	76
6.3	Hyödynnettävyys ja jatkotutkimustarpeet	77
	Lähteet	78

1 Johdanto

Metsiä on inventoitu Suomessa jo yli 100 vuoden ajan. Teknologian kehityksen myötä maastomittauksesta on siirrytty kohti kaukokartoituspohjaista inventointia. Lentokoneiden ja satelliittien hyödyntämisen ansiosta metsistä saadaan inventointitietoa laajoilta alueilta.

Ilmakuvaus lentokoneesta oli ensimmäinen kaukokartoitusmenetelmä, jota Suomessa alettiin käyttämään. Ilmakuvilla on edelleen merkittävä rooli metsien inventoinnissa sekä päivittäisenä apuvälineenä metsäammattilaisille. Etenkin vääräväri-ilmakuvia hyödynnetään puulajin määrittämisessä ja leimikon suunnittelussa (Auvinen, Pukkala & Vesa 2002, 79–124) ja hyönteistuhojen kartoituksessa (Lyytikäinen-Saarenmaa, Kantola, Blomqvist & Kosunen 2015). Puustotunnusten määrittäminen ilmakuvista on haastavaa, sillä niiden resoluutio ei ole riittävän tarkka (Utterera, Anttila, Suvanto & Maltamo 2006).

Satelliittikuvat ovat vielä ilmakuviakin karkeammalla resoluutiolla. Niiden etu on kuvien toistuvuus, sillä ne päivittyvät jopa parin päivän välein. Satelliittikuvien avulla voidaan mm. tunnistaa toteutettuja hakkuita (Sirro, Häme, Rauste, Pitkänen, Kangas, Törmä, Häme, Huotari & Norppa 2019).

Laserkeilaus on tällä hetkellä valtamenetelmänä metsien inventoinnissa, ja sen pohjalta Metsäkeskus tuottaa metsävaratietoa. Maanmittauslaitos koordinoi laserkeilausohjelmaa, ja koko Suomi keilattiin harvalla pulssilla vuosina 2008–2019 (Maanmittauslaitos 2022). Laserkeilausaineistosta tehdään pistepilviä, joista muodostetaan erilaisia maaston ja puuston malleja (Holopainen, Hyyppä & Vastaranta 2013, 10–27). Niiden pohjalta puustotunnukset voidaan estimoida jopa maastomittausta korkeammalla tarkkuudella (Utterera ym. 2006).

Uusimpana teknologiana metsien inventointiin ovat tulleet miehittämättömät ilma-alukset eli dronet. Dronella otetut ilmakuvat ovat korkearesoluutioisia. Niistä metsää voi tarkastella visuaalisesti puunkorjuuseen tai luontokohteisiin

liittyvissä asioissa (Paananen 2018). Toisaalta kuvista voidaan muodostaa fotogrammetristen ohjelmistojen avulla pistepilviä, joista estimoidaan puustotunnuk-
sia kasvatusmetsiköistä (Puliti, Ørka, Gobakken & Næsset 2015) tai taimikoista
(Imangholiloo, Saarinen, Markelin, Rosnell, Nasi, Hakala, Honkavaara, Holopai-
nen, Hyyppä & Vastaranta 2019).

Dronekuvista saadaan tietoa yksittäisen puun tarkkuudella. Niistä voidaan mi-
tata tarkasti puun pituus ja latvuksen koko, joiden pohjalta voidaan mallintaa
puun läpimitta ja tilavuus. Valokuvasta on mahdollista määrittää vain siinä näky-
vät kohteet, joten dronekuvien lisäksi täytyy hyödyntää laserkeilausaineistoa.
Laserkeilausaineistosta saadaan maanpinnan ja aliskasvospuiden sijainti.

Tässä opinnäytetyössä on tarkoitus perehtyä dronekuvien hyödyntämiseen met-
sien inventoinnin apuvälineenä. Tarkoituksena on selvittää dronen kyky tunnis-
taa yksittäiset puut, sekä tarkastella puustotunnusten tulkinnan onnistumista. Li-
säksi selvitetään kalibroitikertoimien avulla lisättyjen aliskasvospuiden tuoma
lisähyöty inventointitulokseen. Tutkimusalue sijaitsi Keski-Ruotsissa ja sinne to-
teutettiin dronelennot sekä maastomittaukset elo-lokakuun aikana vuonna 2022.
Opinnäytetyön toimeksiantaja on AFRY, joka kehittää menetelmiä puutason
kaukokartoitukseen ja puittaisen inventointitiedon käyttöön osana AFRY Smart
Forestry Platform -ohjelmistoalustaa.

2 Kaukokartoitus metsien inventoinnissa

2.1 Kaukokartoitus

Metsävaratiedolla on suuri merkitys metsien hyödyntämisen kannalta. Sen
avulla voidaan seurata Suomen metsien tilaa ja niissä tapahtuvia muutoksia. Se
luo myös pohjan metsäsuunnitelmille, joiden perusteella toteutetaan

metsätalouden toimenpiteitä. Laadukkaan metsävaratiedon avulla voidaan arvioida hakkuukertymät, puuston kasvuennuste ja seuraavan toimenpiteen ajoitus. Sitä voidaan myös hyödyntää tutkimuksissa. Maastossa tehtävät koealamittaukset ovat tarkka, mutta myös hidas ja kallis tapa inventoida metsiä. Kaukokartoituksen tarkoitus on kerätä metsistä laajalti ja edullisesti inventointitietoa. Tyypillisiä kaukokartoitusaineistoja ovat ilmakuvat, satelliittikuvat, laserkeilatut piste-pilvet sekä dronekuvat.

2.2 Aineistojen tulkinta

Kaukokartoitusaineistoja tulkitaan aluepohjaisella tai yksinpuin tulkintamenetelmällä. Yksinpuintulkintaa voidaan käyttää silloin, kun aineisto on riittävän tarkkaa yksittäisten puiden havaitsemiseen ja mittaamiseen. Tällaisia aineistoja ovat dronekuvien tai tiheäpulsseisen laserkeilauksen pohjalta muodostetut piste-pilvet. Aluepohjaista tulkintaa käytetään silloin kun aineisto on karkeampaa. Siinä maastokoealojen tieto yleistetään kaukokartoituspiirteiltään vastaaville alueille. Menetelmää kutsutaan k:n lähimmän naapurin menetelmäksi, ja sitä käytetään ilmakuvien, satelliittikuvien ja harvapulsseisen laserkeilausaineiston tulkinnassa. Ilmakuvista ja satelliittikuvista tarkastellaan pikselien sävyarvoja ja laserkeilausaineistosta pisteiden sijoittumista ja pistepilven muotoa. (Holopainen ym. 2013, 10–27; Talkkari & Lehmonen 2021, 82–86; Hyvönen 2002.)

Kun metsää inventoidaan laserkeilaamalla, aineisto saadaan kolmiulotteisena ja sitä voidaan hyödyntää suoraan puustotunnusten tulkinnassa. Mutta kun metsästä otetaan ilmakuvia, silloin kolmiulotteinen tieto muuttuu kaksiulotteiseksi. Siksi ilmakuvia täytyy käsitellä fotogrammetrian avulla.

Fotogrammetria on tekniikka, jolla kohde saadaan mallinnettua kolmiulotteisesti valokuvien pohjalta. Valokuvassa häviää aina tietoa kohteesta, ja siksi tarvitaan kuvia ainakin kahdesta kulmasta mallintamisen onnistumiseksi. Mitä useammasta kulmasta on kuvia, sitä tarkempi mallista saadaan. Prosessi perustuu

kolmiomittaukseen, jonka avulla saadaan määritettyä pisteen sijainti kolmiulotteisessa koordinaatistossa tunnettujen kulmien ja etäisyyksien perusteella. (Geodetic Services 2017, 4–23.)

2.3 Ilmakuvat

Kaukokartoitusmenetelmistä ilmakuvausta on hyödynnetty metsätaloudessa piisimpään. Ilmakuvat otettiin metsäsuunnittelun apuvälineeksi 1950-luvulla. Lentokoneiden ja kameroiden kehityksen myötä ilmakuvien laatu on parantunut, ja niiden avulla saadaan entistä tarkempaa tietoa. Ilmakuvat ovat passiivinen kaukokartoitusmenetelmä, ja niiden laatu on riippuvainen auringon säteilystä. (Auvinen ym. 2002, 79–124.)

Maanmittauslaitos koordinoi Suomen ilmakuvausohjelmaa. Suomi kuvataan 3 vuoden välein, poikkeuksena Pohjois-Lappi, joka kuvataan 12 vuoden välein. Ilmakuvia tuotetaan mustavalkoisina, värillisinä sekä väri-infrana. (Maanmittauslaitos 2022.)

2.3.1 Ilmakuvauslennot

Ilmakuvauslennot lennetään 7 000–8 000 m:n korkeudessa, ja kuvien maastotarkkuus on 40 cm (Metsäkeskus 2022). Lentolinjat suunnitellaan ennakkoon, ja ne pyritään asettelemaan pääilmansuuntien mukaan, siten jostain kuvan sivusta saadaan pohjoissuuntainen. Ilmakuvat otetaan lentokoneesta kohtisuoraan alaspäin niin, että edellisen kuvan aluetta näkyy seuraavassa kuvassa 60 %. Tätä kutsutaan pituuspeitoksi. Näin jokaisesta kohdasta saadaan kaksi kuvaa, joka helpottaa kuvien tarkastelua. Sivupeiton eli kuvien lentolinjojen suuntaisen päällekkäisyyden on oltava 30 %. (Auvinen ym. 2002, 79–124.)

Ilmakuvauksia tehdään kevästä alkusyksyyn. Silloin on riittävästi valoa ja kasvillisuuden kontrastit ovat selkeät. Pitkien päivien ansiosta myös kuvausaika on pitkä. Auringon korkeuskulman on oltava vähintään 33°, jotta ilmakuvia voidaan ottaa. Sään täytyy olla kirkas, sillä ilmakuvissa ei saa näkyä pilviä eikä pilvien varjoja. (Auvinen ym. 2002, 79–124.) Maanmittauslaitos kuvaa puolet alueistaan keväällä, ennen kuin puissa on lehtiä. Kesällä otetaan ilmakuvat niistä alueista, jotka kyseisenä vuonna myös laserkeilataan. (Maanmittauslaitos 2022.)

2.3.2 Sovelluksia

Ilmakuvat ovat edelleen käytössä metsäammattilaisilla suunnittelun apuvälineinä. Niitä hyödynnetään metsäkuljetusreittien suunnittelussa, varastopaikkojen valinnassa ja ennakkokuvioinnissa.

Tärkein tieto metsien inventoinnin näkökulmasta on metsikön puulaji, koska muilla kaukokartoitusmenetelmillä sen määrittäminen on haasteellisempaa. Ilmakuvan on oltava väri-infrakuva, jotta eri puulajit erottuvat siinä. Väri-infrakuvassa mänty on viherruskea, kuusi on sitä tummempi viherruskea ja koivu purppuranpunainen (Auvinen ym. 2002, 79–124). Väri-infrakuvissa kuolleet kuuset näkyvät kirkkaan turkooseina. Kuvia voidaan hyödyntää esimerkiksi kirjanpajan aiheuttaman tuhoalueen rajaamisessa. (Auvinen ym. 2002, 79–124; Lyytikäinen-Saarenmaa, ym. 2015.)

Ilmakuvaukseen ja laserkeilaukseen liittyvässä tutkimuksessa käsiteltiin kahta tilaa, toinen Keski-Suomessa ja toinen Kaakkois-Suomessa. Yhtenä aineistona tutkimuksessa oli numeerinen ilmakekuva, josta tehtiin puoliautomaattinen yksinpuintulkinta. Tällä menetelmällä saatiin puuston tilavuus 40 %:n ja 47 %:n keskivirheellä. Keskivirhe on liian suuri, jotta puustotunnuksia voitaisiin hyödyntää. Kun ilmakekulle otettiin tueksi laserkeilausaineistoa, tulosten luotettavuus parani. (Utterä ym. 2006, 507–519.)

Ilmakuvia voidaan tulkita myös stereomittauksen avulla. Stereotulkinta perustuu ihmisen silmän kykyyn havaita etäisyyseroja. Apuvälineenä ilmakuviin tarkasteluun käytetään stereoskooppia. Kun kohdetta tarkastellaan kahdesta hieman eri kulmista otetuista ilmakuvista, toista oikealla ja toista vasemmalla silmällä, niin kohde nähdään kolmiulotteisena. Tätä voidaan hyödyntää yksittäisen puun pituuden mittaamiseen. Menetelmän hallitseminen vaatii harjoittelua ja näköhavaintojen huolellista analysointia. Se tekee tulkinnasta hidasta, jonka vuoksi puustotulkintojen tekeminen laajemmassa mittakaavassa ei ole yleistä. (Auvinen ym. 2002, 79–124).

Trap-Johansen (2002, 269–276) tutki ilmakuvista estimoitujen puuston rinnankorkeusläpimittojen luotettavuutta Tanskassa, hoidetussa tammimetsässä. Tutkimuksessa oli käytössä ilmakuvaukseen tyypillistä korkearesoluutioisempi kamera, jolla kuvista saatiin tarkkoja. Kuvauslennoissa oli myös normaalia suurempi sivu- ja pituuspeitto ja jokaista puuta pystyttiin tarkastelemaan viidestä kuvasta. Ilmakuvat prosessoitiin ja rinnankorkeusläpimitat estimoitiin hyödyntäen puiden varjoja, runkomalleja ja pikselien eri harmaansävyjä. Lopputuloksen keskivirhe oli vain -0,4 cm.

Harva tammimetsä oli helppo inventointikohde. Jokaisen puun pystyi erottamaan kuvista, eivätkä latvat sekoittuneet keskenään tai alempia latvuserroksia jäänyt piiloon. Tällä menetelmällä saavutettu tarkkuus ei tuota niin suurta hyötyä, että se kattaisi kameran, lentojen ja kuvien käsittelyn aiheuttamat kustannukset.

2.4 Satelliittikuvat

Satelliitit kiertävät maapalloa ja keräävät tietoa sen joka puolelta. Satelliittikuvat ovat ilmakuviin verrattuna edullisia ja ne päivittyvät useammin. Niitä voidaan hyödyntää laajojen alueiden metsävarojen kartoittamiseen sekä eri ilmiöiden seuraamiseen. Niiden avulla päästään käsiksi myös niille alueille, jotka ovat muuten vaikeasti lähestyttävissä.

2.4.1 Eri satelliitteja

Yleisimpiä metsätalouden hyödyntämiä satelliitteja ovat SPOT, MODIS, Sentinel ja Landsat. Metsätalouden kannalta on olennaista saada korkearesoluutiosta aineistoa, joka päivittyy usein. Etuna on myös se, jos satelliitti ottaa kuvan kyseisestä paikasta aina samaan kellonaikaan. Tällöin auringon suunta on sama, eikä se aiheuta muutoksia pikselien sävyarvoihin.

EU:n ja ESA:n Copernicus -ympäristöohjelmaan kuuluvat Sentinel 2 -satelliitit. Ne ovat tuottaneet korkean resoluution satelliittikuvia vuodesta 2015. Suomen satelliitit kuvaavat 2–3 päivän välein. Aineisto on ilmaista ja sen tarkkuus vaihtelee 10–30 m:iin riippuen kanavasta. (Sirro ym. 2019.)

2.4.2 Soveltaminen metsätaloudessa

Satelliittikuvat ovat liian karkeaa aineistoa puustotunnusten tulkitsemiseksi. Keskikarkean resoluution omaavien satelliittien, kuten Landsat, saadaan puuston keskitilavuus laskettua 45–55 %:n keskivirheellä (Holopainen ym. 2013, 10–27).

Satelliittikuvien avulla voidaan kuitenkin luokitella maa-alueita. Luokkajako voi olla esimerkiksi pelto, vesi, nuoret sekä vanhat havu- ja lehtimetsät sekä rakennetut alueet (Auvinen ym. 2002). Muutostulkinnan avulla alueiden käsittelystä voidaan tehdä johtopäätöksiä. Metsäkeskus hyödyntää Sentinel 2 -satelliittien kuvia hakkuiden seurannassa ja lopputuloksia voidaan verrata tehtyihin metsänkäyttöilmoituksiin. Menetelmä tunnistaa avohakkuut 90 %:n ja harvennukset 40 %:n tarkkuudella. (Sirro ym. 2019.)

Monilähdeinventoinnissa (VMI) hyödynnetään satelliittikuvia maastosta mitattujen koealatietojen tukena. Satelliittikuvien avulla maastotiedot voidaan yleistää

koealaverkkoa suuremmalle alueelle. Apuna käytetään myös peruskarttoja ja korkeusmalleja. Monilähdeinventoinnilla saadaan pienempien alueiden, esimerkiksi kuntakohtaiset inventointitulokset. (Luke 2015.)

VESA-indeksi on Terramonitorin tekemä kasvillisuusindeksi, joka perustuu Sentinel 2 -satelliittikuviin. Sen avulla pyritään ennustamaan taimikoiden vesakoitumista. Tulokset ovat kuitenkin vielä liian epätarkkoja hyödynnettäväksi operatiivisessa suunnittelussa. (Seppälä 2021.)

Hyönteistuhojen seurantaan voidaan hyödyntää satelliittikuvia. Tuhoalueiden muutoksia ja etenemistä voidaan seurata, koska alueesta saadaan kuvia toistuvasti. Suomessa on seurattu Landsat satelliitin avulla pikkumäntypistiäisen tuhoja. Mitä karkeampi resoluutio satelliitissa on, sitä laajempia on tuhoalueiden oltava, jotta ne voidaan erottaa kuvista. MODIS satelliitin resoluutio on 250–500 m ja se kuvaa saman alueen 8 vuorokauden välein. Sen kuvien avulla on seurattu ruskomäntypistiäisen, lehtinunnan ja Siperian mäntykehräjän tuhoalueita. (Lyytikäinen-Saarenmaa ym. 2015.)

2.5 Laserkeilaus

Laserkeilaus on tällä hetkellä merkittävin metsien kaukokartoitusmenetelmä. Keilata voi ilma- tai maalasereilla, mutta kun tarkoituksena inventoida metsiä, laserkeilaus toteutetaan lentokoneesta tai helikopterista.

Maanmittauslaitos laserkeilasi Suomen kokonaan harvalla pulssilla vuosina 2008–2019. Vuonna 2020 alkoi toinen kierros, jossa kerätään tiheäpulsseista aineistoa. (Maanmittauslaitos 2022.)

2.5.1 Laitteisto ja lennot

Laserkeilauslaitteistoon kuuluvat keilain, lasertykki sekä järjestelmät tiedon tallentamiseen ja sijainnin paikannukseen. Lasertykki tuottaa laserpulsseja, jotka keilain pyyhkäisee lentosuuntaan nähden poikittain kohti maanpintaa. Inertialaitteisto tallentaa keilaimen asennon ja GNNS-vastaanotin sijainnin. Kun pulssi on osunut kohteeseen ja ottanut siitä kaiun takaisin keilainlaitteistoon, saadaan selville siihen kulunut aika. Valonnopeus on vakio, joten sen ja keilaimen sijaintitietojen avulla, voidaan määrittää kohteen x, y, z -koordinaatit. (Holopainen ym. 2013, 10–27.)

Lasertykistä lähetettyä pulssia kutsutaan keilaksi. Keilan leveys maanpinnalla on 0,1–3,8 m. Tästä syystä samasta laserpulssista voi tulla useita kaikuja. Ne voivat tulla eri korkeuksilta, esimerkiksi puun latvasta, rungosta ja maasta. Kun laserpulssien syöttöä toistetaan ja kaikujen x, y, z -koordinaatit selvitetään, alkaa muodostua pistepilveä. (Holopainen ym. 2013, 10–27.)

Laserkeilaus on aktiivinen kaukokartoitusmenetelmä, eikä sen laatu ole riippuvainen auringon säteilystä. Siksi lennon sää ja vuorokaudenaika ei ole yhtä rajoittunut kuin ilmakuvauksella. Laserkeilauslennot lennetään 400–4 000 metrin korkeudessa. Keilauskulma, eli kulma jolle keilain pyyhkäisee laserpulsseja, on yleensä 15 astetta. Lentokorkeuden ja keilainkulman avulla voidaan säätää lentolinjan leveyttä. Lentolinjojen välillä on 10–50 %:n sivupeitto. (Holopainen ym. 2013, 10–27)

2.5.2 Harvapulssiaineisto

Laserkeilausaineistot luokitellaan joko harva- tai tiheäpulssisiksi keilauksessa käytetyn pulssitiheyden mukaan. Harvapulssisessa aineistossa neliömetrille osuu 0,5–2 pulssia. (Holopainen ym. 2013, 10–27.)

Harvapulssinen aineisto tulkitaan aluepohjaisesti. Aineistosta poimitaan otos, joka on yleensä 16 m:n x 16 m:n suuruinen hilaruutu. Hilaruutuun pyritään liittämään piirteiltään mahdollisimman lähellä olevat referenssiaineistot, eli esimerkiksi maastokoealat. Koealojen metsikkötunnuksista lasketaan keskiarvot ominaisuuksiltaan samankaltaisimpia painottaen. Jotta metsikkötunnukset ovat käytettävämässä muodossa, ne yleistetään hilaruuduilta kuviotasolle. Piirteitä, joita pistepilvestä tarkastellaan ovat esimerkiksi pisteiden korkeusjakauma, pisteiden sijoittumiset kullekin kaulle sekä kasvillisuuteen osuneiden pisteiden osuus. Tulkinnan tarkkuus riippuu koealojen tietojen tarkkuudesta, siksi on tärkeää suunnitella koealaverkko siten, että se kuvastaa koko inventointialuetta. (Holopainen ym. 2013, 10–27; Talkkari & Lehmonen 2021, 82–86; Hyvönen 2002.)

2.5.3 Tiheäpulssiaineisto

Tiheäpulssisessa laserkeilausaineistossa neliömetrille osuu 5–30 pulssia. Pistepilvestä saadaan harvapulssiseen aineistoon verrattuna yksityiskohtaisempi. Tämä mahdollistaa yksinpuintulkintamenetelmän käytön.

Yksinpuintulkinnassa suodatetaan puuston pituusmallia (CHM). Mallista etsitään paikalliset maksimit, jotka kertovat puun pituuden ja sijainnin. Puun pituuden avulla voidaan johtaa rinnankorkeusläpimitta ja tilavuus allometrisien mallien avulla. (Holopainen ym. 2013, 10–27.)

2.5.4 Sovelluksia

Pistepilvestä voidaan tehdä erilaisia malleja. Maanpinnan korkeusmalli (Digital Elevation Model, DEM) on numeerinen malli, joka kuvaa pinnanmuotoja.

Maanpinnan maastomalli (Digital Terrain Model, DTM) sisältää maanpinnan karkeuden ja siitä on havaittavissa rinteiden kaltevuudet ja viettosuunnat. Maanpintaa kuvaavat mallit saadaan laserpulssien viimeisistä kaiuista. (Holopainen ym. 2013, 10–27; Maanmittauslaitos 2022.)

Ensimmäisistä kaiuista saadaan korkeimpien kohteiden pintamalli (Digital Surface Model, DSM). Tämä pintamalli seuraa puiden latvusta ja aukkoisilla kohdilla maanpintaa. Siitä voidaan havaita metsien rakennevaihdokset, ojat, tiet ja rakennukset. Kun korkeimpien kohteiden pintamallista (DSM) vähennetään maanpinnan maastomalli (DTM) saadaan puuston pituusmalli (Canopy Height Model, CHM). Puuston pituusmallista tulee ala-arvio, sillä ensimmäinen kaiku saadaan harvoin aivan latvasta ja tiheä aluskasvillisuus voi antaa maastomalliin yliarvion. (Holopainen ym. 2013, 10–27; Maanmittauslaitos 2022.)

Useissa tutkimuksissa on osoitettu, että laserkeilausaineiston avulla estimoidut puustotunnukset ovat kaikista luotettavimpia. Seuraavissa kolmessa tutkimuksessa aineisto oli harvapulssista ja niihin tehtiin aluepohjainen tulkinta, käyttäen k:n lähimmän naapurin menetelmää. Lopputuloksena kaikissa tutkimuksissa päästiin puuston tilavuuden osalta alle 20 %:n, jopa alle 10 %:n keskivirheeseen. Myös muiden puustotunnusten ennustaminen onnistui hyvin. Tulokset ylisivät parempaan tarkkuuteen, kuin maastoinventoinnilla mitatut. (Uttera ym. 2006, 507–519; Maltamo ym. 2008, 304–309; Suvanto ym. 2005, 413–428.)

	H	D	G	V
Solmu	15	14	18	22
Ilmakuva	12	12	34	33
Laserkeilaus	9	13	23	19

Taulukko 1. Puustotunnusten RMSE% Solmu -maastomittaukseen, ilmakuvaan ja laserkeilaukseen perustuvissa inventoinneissa. (Uttera ym. 2006.)

Puulajitulkinnan oikeellisuus on tärkeää, jotta muiden puustotunnusten estimoimiseen osataan valita oikeat runkomallit. Sillä on merkittävä vaikutus inventointitulosten luotettavuuteen. Puulajitulkinnassa käytetään yleisesti vielä ilmakuvia. On kuitenkin tehty tutkimuksia pelkän laserkeilausaineiston avulla tunnistetuista puista. Mikäli menetelmä saadaan kehitettyä riittävän pitkälle se mahdollistaisi metsien kartoituksen perustumisen pelkästään laserkeilaukseen.

Laserkeilauksessa intensiteetti kuvaa paluukaiun voimakkuutta. Siihen vaikuttavat muun muassa kohteen heijastuvuus ja rakenne, ilmakehän tila sekä keilaimen asetukset. Intensiteetin hyödyntämiseen liittyy vielä epätarkkuuksia, koska siihen vaikuttaa moni tekijä ja kalibroiminen on haastavaa. (Holopainen ym. 2013.) Puulajien erottelu laserkeilausaineistosta perustuu kaikujen intensiteettiin. Tutkimuksessa valtapuiden luokittelu oli saatu onnistumaan 88–90 %:n tarkkuudella. Tutkimusaineisto oli tiheäpulsseista, jossa neliömetrille osui 6–8 pulssia. Korkein intensiteetti on puilla, joilla on suuret lehdet ja tiheä latvus, kuten vaahteralla. Koivulla on korkeampi intensiteetti kuin männyllä ja kuusella. Puun intensiteettiarvoon vaikuttivat lehtien ja neulasten muoto sekä asento. Lisäksi puun absoluuttinen ja suhteellinen koko sekä naavakasvustot oksilla muuttivat arvoa. Myös keilaimien välillä havaittiin eroja, joiden syytä tutkimuksessa ei osattu määrittää. Nämä asiat tekevät intensiteetin hyödyntämisen haastavaksi. (Korpela, Ørka, Maltamo, Tokola & Hyypä 2010.)

Myös tukkisaannon ennustamista laserkeilausaineistosta on tutkittu. Siinä käytetään referenssiaineistona hakkuukoneesta saatavaa runkopankkiaineistoa (STM). Tutkimuksessa oli aineistona harvapulssinen laserkeilausaineisto, vääräriilmakuvat ja hakkuukoneen STM-tiedostot. Tukkisaanto arvioitiin laserkeilausaineistoon perustuvia läpimitta- ja korkeusjakaumia käyttäen. Lopputulokset eivät olleet luotettavia, sillä männyn RMSE oli 62 % ja kuusen 32 %. Tukkisaannon ennustaminen on vaikeaa, koska puiden pituus-läpimittasuhteet ja puulajisuhteet eivät ole suoraan yhteydessä tukin laatuvaatimukseen. (Peuhkurinen, Maltamo & Malinen 2008.)

Tuoreemmassa tutkimuksessa oli käytössä tiheäpulssinen laserkeilausaineisto, 13 pulssia neliömetrille. Siitä huolimatta kaiut saadaan yleensä puun latvuksesta tai oksista, jotka eivät kerro tukin laatuominaisuuksista mitään. Tässä tutkimuksessa referenssiaineistona olivat maastomittaukset, jossa kaikista tukkimännystä oli mitattu myös 6 m:n läpimitta. Niistä johdettiin Laasasenahon runkokäyrämallien avulla tukkisaannot. Laserkeilausaineistoa analysoitaessa käytettiin erilaisia malleja, joilla pyrittiin löytämään yhteys pistepilven ja tukkisaannon välillä. Parhaaksi osoittautui lineaarisella sekamallilla saatu tulos, jossa männyn tukkisaannon RMSE oli 21 %. (Karjalainen, Packalen, Rätty & Maltamo 2019.)

2.5.5 Metsävaratieto

Metsäkeskus tuottaa kuviokohtaista metsävaratietoa Suomen metsistä. Metsävaratietoa ei kerätä enää maastoinventoinneilla, vaan on siirrytty kaukokartoituspohjaiseen menetelmään. Menetelmä perustuu laserkeilausaineistoon, ilmakuviin, referenssikoealoihin ja näistä tilastollisilla menetelmillä tehtyihin puustotulkintoihin. Inventointialueita kartoitetaan 22 vuodessa, ja ne ovat suuruudeltaan 300 000 ha, josta noin puolet on metsää. Yhdeltä inventointialueelta mitataan 700–900 kpl 9 m:n kiinteäsäteisiä koealoja tai 150–200 puukarttakoealaa. (Metsäkeskus 2022.)

Puukarttakoealat ovat 1 000–2 000 neliömetrin suuruisia ja niistä mitataan myös puiden tarkat sijainnit. Yhdeltä puukarttakoealalta voidaan rajata useita inventointiyksiköitä. Inventointiyksiköt ovat joko 16 m:n x 16 m:n hilaruutuja tai automaattisesti segmentoituja latvusrajattuja puuryhmiä. Latvusrajatut puuryhmät ovat laserpiirteiltään tarkempia, koska puut eivät leikkaudu niissä. Inventointiyksiköistä yleistetään tiedot kuviotasolle. Laatuksiteereinä on saada pohjapinta-ala $\pm 3 \text{ m}^2/\text{ha}$, keskiläpimitta $\pm 3 \text{ cm}$, keskipituus $\pm 2 \text{ m}$ ja tilavuus $\pm 20 \%$:n tarkkuudella 8:ssa tapauksesta 10:stä nuorissa varttuneissa ja uudistuskypsissä

metsissä. Taimikoiden osalta on tavoitteena 50 %:n tarkkuus runkoluvussa. (Metsäkeskus 2022.)

Laserkeilauksen ja ilmakuvauksen kustannukset ovat noin 5 € ha:lta. Maastoinventoinnin kustannukset ovat puolestaan 20 € ha:lta. Kun korvataan maastoinventointi kaukokartoituksella, saadaan pienennettyä inventointikustannuksia neljäsosaan ja saadaan kustannussäästöjä. Laadukkaan ja kustannustehokkaan metsävaratiedon avulla Metsäkeskus valvoo hakkuita ja Kemera -kohteita. Valvonta voidaan kohdentaa paremmin ja useampi virheellisin perustein tukia hakenut jää kiinni. Esimerkiksi pelkästään nuoren metsän hoidon tarkastukset tuottavat vuosittain 150 000 € kustannussäästöt. (Kangas, Haara, Holopainen, Luoma, Packalen, Packalen, Ruotsalainen & Saarinen 2019.)

Laadukkaasta metsävaratiedosta on taloudellista etua myös metsänomistajalle. Maastossa mitatun tiedon RMSE on 25 % ja kaukokartoitetun 15 %. Tämä antaa 60 miljoonan euron lisähyödyn vuosittain metsänomistajakunnalle. Jos verrataan satelliittikuvien pohjalta tuotettuun metsävaratietoon, hyöty on kolminkertainen. Jo vain 1 % RMSE parantuminen metsävaratiedossa nosti metsänomistajan tuloja noin 4 € ha:lta. Inventointikierto viiden vuoden välein on tutkimuksen mukaan kannattavampaa, kuin vanhan inventointitiedon päivittäminen kasvumalleilla. Viiden vuoden välein tehtävä inventointi tuotti metsänomistajalle 56 € hehtaarikohtaisen lisähyödyn. Näin ollen Maanmittauslaitoksen kuudenvuoden inventointikierto on järkevä myös metsänomistajien kannalta. Puulajin määrittämiseen kaukokartoitusaineistosta liittyy eniten ongelmia. Tutkimuksessa todettiin että, siitä aiheutuneet virheet aiheuttavat niin suuren tappion, että maastotarkastus tulee kannattavaksi investoinniksi. (Kangas ym. 2019.)

2.6 Metsien inventointi dronella

Dronella tarkoitetaan miehittämätöntä ilma-alusta. Se on kauko-ohjattava lennokki, johon voidaan liittää erilaisia sensoreita. Dronejen käyttö metsätaloudessa on lisääntynyt viime vuosien aikana. Dronejen, kameroiden sekä


prosessointiohjelmistojen kehittyminen on mahdollistanut entistä tarkemman tiedon keräämisen metsistä. Dronejen avulla päästään myös keräämään tietoa alueista, joiden tiedot jäivät muilla kaukokartoitusmenetelmillä puutteellisiksi.

2.6.1 Dronetekniikkaa


Dronet ovat yleensä sähkökäyttöisiä, mutta isoimmissa malleissa voi olla polttomoottori. Dronet voivat olla moniroottorisia tai kiinteäsiipisiä. Moniroottorinen drone on kätevämpi liikkeissään kuin kiinteäsiipinen drone. Sillä pystyy lentämään moneen suuntaan, pysymään paikoillaan, lentämään hitaasti ja liikkumaan myös korkeussuunnassa. Kiinteäsiipinen drone puolestaan vaatii kiitoradan ilmaan nousemiseksi ja sen on pysyttävä riittävässä nopeudessa ilmassa pysymiseksi. (Droneinfo 2022.)

Moniroottoriset dronet ovat siis kuin helikoptereita ja kiinteäsiipiset kuin lentokoneita. Kiinteäsiipisiä droneja hyödynnetään laajojen alueiden kartoitukseen ja moniroottorisia kuvaamiseen. Yleisimmin käytössä on moniroottorinen drone, jonka kunkin neljän varren päässä on moottori. Kahta propellia moottorit pyörittävät myötäpäivään ja kahta vastapäivään. Siten kiertovoimat kumoavat toisensa ja drone nousee ilmaan. (Droneinfo 2022.)

Dronen lentolinjat suunnitellaan huolellisesti, jotta alue saadaan kuvattua mahdollisimman tehokkaasti (kuvat 1 ja 2). Drone lentää ohjelmoituja linjoja pitkin automaattisesti. Lentolinjojen pituus- ja sivupeitto ovat tyypillisesti 80 %. Pilotin tehtävänä on pitää jatkuvasti näköyhteys droneen ja tarvittaessa ohjata dronea manuaalisesti.



Kuva 1. Lentosuunnitelma (Kuva: Korhonen.)



Kuva 2. Lennon kuvanottoaikkojen sijainti. (Kuva: Korhonen.)


Dronelennot toteutetaan matalalla, yleensä noin 100–150 m:n korkeudessa (Droneinfo 2022.) Tästä syystä dronekuva kattaa pienen pinta-alan, mutta sen

geometrinen resoluutio on korkea. Geometrisellä resoluutiolla tarkoitetaan pikselin kokoa maastossa eli pienintä mahdollista yksityiskohtaa, joka kuvasta voidaan erottaa (Törmä 2004). Vaihtamalla dronessa käytettävää kameraa, voidaan säädellä kuvien spektraalista resoluutiota. Spektraalinen resoluutio kertoo kyvystä havaita eri aallonpituusalueita (Törmä 2004).

Dronesta löytyy paikannus- ja inertialaitteisto. Ne tallentavat dronen sijaintia ja asentoa kuvanottohetkellä. Jotta dronekuvien sijaintitarkkuus saadaan nostettua metreistä senttimetrien tarkkuuteen, tarvitaan georeferointia. Georeferointi voidaan tehdä maastosta tunnettujen pisteiden avulla (GCP, Ground Control Points) tai käyttämällä RTK- (Real Time Kinematic) tai PPK- (Post Processing Kinematic) paikannusjärjestelmiä. (Pix4D 2023.)

GCP-pisteet ovat musta-valkoruudullisia laattoja, joiden keskipisteen tarkat koordinaatit mitataan. Niitä sijoitellaan vähintään 5 kuvattavan alueen nurkkiin ja keskelle. Kun dronekuvat ajetaan fotogrammetriseen ohjelmistoon, esimerkiksi Pix4Dengineen, se tunnistaa laatat automaattisesti. GCP-pisteiden avulla tutkimusalueen kuvien pystysuuntaisessa (z-koordinaatit) tarkkuudessa päästiin 6,6 cm:iin. (Pix4D 2023.)

RTK- ja PPK-paikannusjärjestelmän voi hankkia droneen lisälaitteena. Lisäksi tarvitaan tukiasema. Se voi olla kolmijalallinen GNSS-vastaanotin tai virtuaalinen tukiasema, jolloin fyysistä laitetta ei tarvita. Myöskään GCP-laattoja ei tarvita. RTK-paikannuksessa dronen GNSS-vastaanotin kerää tietoja satelliiteista ja tukiasemista jatkuvasti lennon aikana. Maastoesteet, jotka katkaisevat yhteyden droneen, aiheuttavat epätarkkuuksia lopputulokseen. PPK-paikannuksessa tätä ongelmaa ei ole, sillä dronen GNSS-vastaanotin ja tukiasema, eivät ole lennon aikana yhteydessä (kuva 3). Tällöin saadaan katkeamatonta dataa molemmilta ja dronekuvien sijainnit korjataan jälkiprosessoinnissa. Aiemmin mainitulla tutkimusalueella RTK- ja PPK-järjestelmillä varustettujen dronejen kuvissa saavutettiin 2,5 cm:n tarkkuus. (Pix4D 2023.)



Kuva 3. PPK-paikannus. (Kuva: Nordic Drones.)

Metsien inventointiin käytetään esimerkiksi Nordic Drones Oy:n GeoDrone 6 maanmittausdronea. Se on neliroottorinen drone, joka painaa noin 5 kiloa. Dronen runko on tehty titaanista ja hiilikuidusta. Se on kevyt, minimoi moottorin aiheuttaman värinän ja suojaa elektroniikkalaitteistoa sääolosuhteilta. Dronen lentoaika on 74 minuuttia ja siinä ajassa ehditään kuvaamaan 100 ha:n alue. Maksimi tuulenopeus lentäessä on 15 m/s. Sensoreiksi droneen voi valita 24. tai 42. megapikselin RGB-kameran, lämpökameran, multispektrikameran, hyperspektrikameran tai laserkeilaimen. Dronen laitteistoon kuuluu myös GNSS-paikannin ja lisäosaksi voi hankkia PPK-paikannusjärjestelmän. Dronen lento-suunnitelman laatimista varten on Windows-pohjainen ohjelmisto. (NordicDrones 2022.)

2.6.2 Sensorit

RGB-kamera on yleinen sensori droneissa. Se on tavallinen digitaalikamera ja se ottaa kuvia kolmella kanavalla. Kuvissa on nähtävissä silmällä erotettavat värit. Kamera on yleensä kiinnitettyä gimbaaliin, joka vakauttaa lennossa otettuja kuvia. (NordicDrones 2022.) Dronella otettua kuvaa ja lentokoneesta otettua ilmakuvaa voi vertailla kuvista 4 ja 5.



Kuva 4. Dronekuivissa on korkea geometrinen resoluutio. 1:1 500, pikselikoko 10 cm. (Kuva: Paananen.)



Kuva 5. Ilmakuva samasta kohdasta ja samalta vuodelta. 1:1 500, pikselikoko 40 cm. (Kuva: Paananen.)

Multispektrikamerat ottavat kuvia useilla kanavilla. Niiden avulla saadaan tietoa, jota ihmissilmällä ei voi nähdä. Kamera kerää lähi-infrapun aallonpituutta, josta saadaan tehtyä väärävärivuvia. (Pix4D 2022.) Lähi-infrapunaa tarkkailemalla voidaan muodostaa kasvillisuusindeksejä, ja seurata kasvillisuuden toiminnallisia ominaisuuksia, kuten yhteyttämistä (VTT 2023).

Hyperspektrikameralla saadaan spektraalisesti tarkimpia kuvia. Se mittaa kohteen heijastusominaisuuksia jopa tuhannella eri kanavalla (Senop 2022). Hyperspektrikameralla saadaan selville kohteen kemiallinen koostumus. Sen avulla voidaan seurata kasvien stressitilaa ja tunnistaa kasvitauteja. (VTT 2023.)

Dronen sensori voi olla kameran sijasta myös pieni laserkeilain. Sillä saadaan erittäin tiheää aineistoa, 60–1 500 pistettä neliömetrille, joten sitä voidaan käyttää yksittäisten puiden tarkkaan mallintamiseen. Laserkeilain on painava ja pulssit verrattain heikkoja, jonka vuoksi dronella on lennettävä matalalla. Kun joudutaan lentämään matalalla, lentolinjoista tulee kapeampia. Näistä syistä lennot vievät enemmän aikaa ja dronen akut kuluvat nopeammin. Boreaaliset metsät ovat harvoja ja niissä on usein vain yksi latvuskerros. Siksi laserkeilaaminen dronella ei tuota merkittävää lisäarvoa valokuva-aineistoon verrattuna. Sademetsissä, jossa kasvusto on tiheää ja kerroksellista, sillä voitaisiin saada laadukasta inventointitietoa metsistä. (Puliti ym. 2015.)

2.6.3 Dronekuvien tulkinta ja sovellukset

Numeerisesti dronekuvia voidaan tulkita fotogrammetrian avulla. Fotogrammetrian avulla kaksiulotteisista kuvista muodostetaan kolmiulotteinen malli kohteesta. Menetelmän edellytyksenä on, että samasta kohdasta on otettu useita kuvia.

Agisoft Photoscan on ohjelmisto fotogrammetriseen tulkintaan. Sitä voi käyttää sekä Windowsin että Macin käyttöliittymillä. Dronekuvien käsittely on hidas prosessi ja kuvien laatu ratkaisee sen onnistumisen. Prosessi perustuu SfM (Structure from Motion) - ja MVS (Multi-view stereo) -työkalujen käyttöön. Ensimmäisessä vaiheessa ohjelmisto muodostaa harvan pistepilven ja listaa kameran asennot kuvien ottohetkeltä. Harva pistepilvi muodostuu, kun kuvista haetaan vastinpisteitä ja ne asetetaan x, y, z -koordinaatistoon. Toisessa vaiheessa ohjelmisto rakentaa kuvien ja kameran asentojen mukaan tiheän pistepilven.

Kolmas vaihe on rekonstruktiovaihe. Siinä ohjelmisto muodostaa Mesh- ja DEM-pintamallit. Mesh on verkkomalli, joka voidaan tehdä harvan tai tiheän pistepilven pohjalta. Neljäs vaihe on teksturointi, jonka tavoitteena on selkeyttää lopputulosta. Siinä ortokuvat kiinnitetään pintamalliin eli pintamalli saa väriarvot. (Agisoft 2018.)

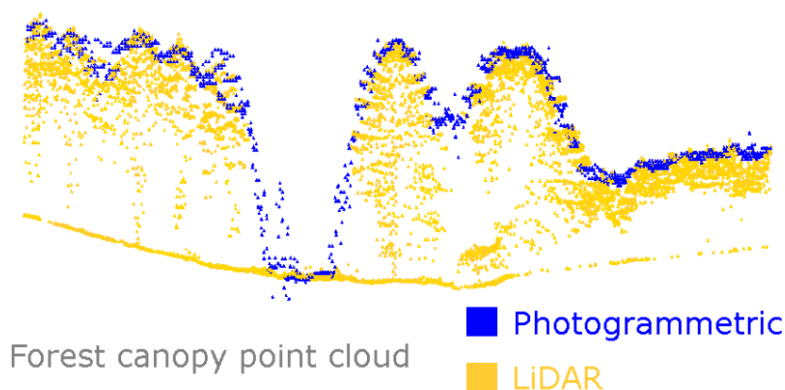
Dronekuvien pohjalta voidaan muodostaa metsikön latvuksen korkeusmalleja (CHM). Aluksi dronekuvista muodostetaan fotogrammetriaohjelmiston avulla pintamalli (DSM), josta vähennetään laserkeilausaineistosta tehty maastomalli (DTM). Lopputuloksena saadaan CHM. Näiden mallien muodostukseen liittyvässä tutkimuksessa käytettiin 8 cm:n resoluution multispektrisiä dronekuvia ja tiheää laserkeilausaineistoa, jossa oli 13 pistettä neliometrillä. Dronekuvista tehty CHM oli laadukas. Laserkeilauspohjaiseen CHM:ään verrattuna keskihajonta oli 0,48 m. Metsikön valtapituuden RMSE oli 8,4 % ja yksittäisen puun pituuden 4,7 %. Nämä ovat vain yhden prosenttiyksikön heikommat tulokset, kuin laserkeilausaineistosta saadut. Dronekuvien CHM voidaan hyödyntää tiheiden mallien luomiseen ja laserkeilauspohjaisten aineistojen päivitykseen. (Lisein, Pierrot-Deseilligny, Bonnet & Lejeune 2013.)

Norjalaisessa tutkimuksessa selvitettiin dronella tehdyn inventoinnin onnistumista. Tutkimusalueen metsä oli hoidettua talousmetsää lehtimetsävyöhykkeellä ja pääpuulajeja olivat kuusi, mänty ja hieskoivu. Droneaineiston lisäksi alueelta oli käytettävissä tiheäpulsista laserkeilausaineistoa. Laserkeilausaineistosta tehtiin maanpinnan malli (DTM), jota käytetään apuna puiden pituuden mittaamiseen. Alue lennettiin 120 m:n korkeudessa kiinteäsiipisellä SenseFLy eBee -dronella, jossa oli multispektikamera. Lentolinjat suunniteltiin siten, että kuvien sivupeitoksi saatiin 80 %. Puustotunnusten suhteellinen RMSE, suhteellinen harha ja ristiinvaldoinnista saatu selityskerroin R^2 löytyvät taulukosta 2. (Puliti ym. 2015.)

	G	V	H _{keski}	H _{valta}	N
harha%	9	21	3	4	36
RMSE%	15	15	13	4	39
R ²	0,6	0,85	0,71	0,97	0,6

Taulukko 2. Puustotunnusten tarkkuudet tutkimusalueella. G=pohjanpinta-ala, V=keskitilavuus, H_{keski}=keskipituus, H_{valta}=valtapituus ja N=runkoluku. (Puliti ym. 2015)

Tuloksista voidaan havaita, että valtapituuden määrittäminen onnistuu dronekuvista paremmin kuin keskipituuden. Tämä johtuu siitä, että valokuvasta havaitaan vain yksi pinta. Dronekuvista ei voida määrittää lainkaan aliskasvospuita ja matalampien puiden päälle muodostuvat varjot voivat heikentää niiden tulkintaa. Dronekuvista ei saada myöskään maastomallia, jota tarvitaan puiden pituuden määrittämiseen. Siksi droneinventoinnin tueksi tarvitaan laserkeilausaineistoa, jossa samasta pulssista voidaan saada useita kaikuja. (Kuva 6)



Kuva 6. Dronella kuvattujen (sininen) ja laserkeilattujen (keltainen) pisteiden ero (Lisein ym. 2013.)

Pulitin ym. (2015) tutkimuksen mukaan on olennaista löytää sellaiset kohteet, joissa dronella saatavan tiedon arvo on niin korkea, että se kattaa siitä aiheutuvat kustannukset. Kuvauslentojen myöhäinen ajankohta (27.11.–3.12.) heikensi kuvien laatua ja lyhensi kuvausaikaa. Olosuhteista huolimatta kuvaukset ja aineiston tulkinta onnistuivat hyvin. Vastaavissa olosuhteissa ilmakuvaaminen

olisi mahdotonta. Droneinventoinnin kausi on siis pidempi kuin ilmakuvauksessa. (Puliti ym. 2015.) Dronekuvauksen etuna on, että lennot tehdään pilvi-
peitteen alapuolella, eli kun sää on täysin kirkas tai pilvinen, lennot onnistuvat.

Yksi tapa tulkita dronekuvista puulajeja ja muita puustotunnuksia on CNN (Convolutional Neural Network) -menetelmä. CNN-menetelmässä tietokone oppii itse yhteyksiä asioiden välillä eli syväoppii. Puiden latvukset rajataan dronekuvista suodattamalla ja etsimällä paikallisia maksimeita. Tämän jälkeen tietokone luokittelee pikseliryhmät. Tätä kutsutaan hahmontunnistukseksi. (Grybas & Congalton 2021.)

Puulajien erotteluun liittyvässä tutkimuksessa dronen sensoreina oli sekä RGB – että multispektrikamera. Tutkimusalue sijaitsin Yhdysvalloissa ja alueella kasvoi 14 eri puulajia. Puulajien erottelu onnistui RGB-kameralla parhaimmillaan 61 %:n tarkkuudella ja multispektrikameralla 56 %:n tarkkuudella. Sinisen värin aallonpituus osoittautui ratkaisevammaksi, kuin lähi-infrapunan. On siis kannattavampaa valita käyttöön tavallinen RGB-kamera tai multispektrikamera, jossa on myös sinistä aallonpituutta keräävä kanava. (Grybas & Congalton 2021.)

Suomessa merkittäviä puulajeja, joita dronekuvista pitäisi tunnistaa on vain mänty ja kuusi sekä yhtenä luokkana lehtipuut. Se on vähän muiden maiden metsiin verrattuna, joissa lajeja voi olla kymmeniä tai jopa satoja pienellä alueella. Tämä antaa hyvät edellytykset saada puulajitunnistus onnistumaan Suomen metsissä paremmalla tarkkuudella.

Suomessa dronekuvien avulla tehdyssä puulajitulkinnassa onkin saavutettu 95 %:n tarkkuus. Tutkimuksessa eroteltiin mänty, kuusi, koivu ja haapa. Käytössä oli multispektrikameralla sekä RGB-kameralla otettuja kuvia. RGB-kuvat olivat 3,8 cm:n maastoerotuskyvyllä ja multispektrikuvat 9 cm:n. Kuvista tuotettiin Agisoftin SfM -työkalulla pistepilvi, josta segmentoitiin latvukset ja eroteltiin puulajit. RGB-kuvista tuotettu tulkinta oli multispektrisiä kuvia tarkempi, koska korkeamman resoluution ansiosta pistepilvistä saatiin tiheämpi. Se vähensi virheitä

latvusten segmentoinnissa. (Hardenbol, Kuzmin, Korhonen, Korpelainen, Kumpula, Maltamo & Kouki 2021)

Hyperspektrikamerat avaavat aivan uuden tarkkuuden puulajitulkintaan. Tutkimuksessa, jossa aineistona käytettiin hyperspektri kuvia, RGB-kuvia ja CHM-malleja saatiin erittäin lupaavia tuloksia. Hyperspektrikuvissa oli 37 kanavaa. Aineistoja prosessoitiin 3D-CNN-menetelmän avulla ja parhaan tuloksen antoi hyperspektri ja RGB-kuvien yhdistelmä. Mänty määritettiin 99,6 %:n, kuusi 94,8 %:n ja koivu 97,4 %:n tarkkuudella. (Nezami, Khoramshahi, Nevalainen, Pölonen, & Honkavaara 2020.)

Taimikoista ei saada riittävän luotettavaa tietoa ilmakuviin, satelliittikuviin tai laserkeilaukseen perustuvassa kaukokartoituksessa. Dronejen avulla voidaan täydentää inventointitietoa niiden osalta ja vähentää kalliiden maastomittausten määrää. Puustotunnukset saadaan samaan tapaan eli paikantamalla latvukset hahmontunnistuksella tiheästä pistepilvestä. Guillermo ym. (2020) mittasivat taimien pituuksia dronekuvista, jolloin saatiin RMSE 40 %. Imangholiloo ym. (2019) tutkimuksessa taimikon tiheyden RMSE oli 27 % ja pituuden 12 %. Puustotunnusten määrittäminen onnistuu hyvin, mutta laadukkaiden kuvien merkitys korostuu, jotta taimen kärki saadaan havaittua.

Koska dronejen avulla voidaan inventoida pieniä alueita verrattuna muihin kaukokartoitusmenetelmiin, referenssikoealojen mittauskustannukset ovat suhteessa korkeat. Siksi tulokinnan apuna kannattaa käyttää Luken tekemiä tilavuusmalleja. Luken mallit perustuvat Laasasenahon aineistoon, kaatokoepuista mitattuun VAPU-aineistoon sekä maalaserkeilattuun aineistoon (Luke 2023). Mikäli inventoitavasta alueesta ei ole käytössä puiden runkomalleja, on referenssikoealat käytävä mittaamassa.

3 Tutkimuksen tausta ja tavoitteet

Metsävaratiedolla on olennainen merkitys strategisessa päätöksenteossa. Tarkemmalla metsävaratiedolla voidaan saavuttaa taloudellista etua, kun toimenpiteet voidaan suunnitella optimaalisemmin. Dronet ovat uusi teknologia metsäalalla, ja niiden hyödyntämismahdollisuuksia on tärkeää selvittää. Tämän opinnäytetyön tavoitteena on tutkia fotogrammetrian avulla tulkittuja dronekuvia inventointimenetelmänä. Toimeksiantaja opinnäytetyöhön on AFRY.

AFRY on kansainvälinen konsulttiyhtiö, jolta löytyy asiantuntemusta teollisuus-, energia-, ympäristö- ja digitalisaation aloilta. AFRY toiminta perustuu investointihankkeisiin ja eri prosessien suunnitteluun. Vuonna 2021 AFRY osti Simosol Oy:n ja MosaicMill Oy:n. Simosol oli metsien simuloimiseen ja optimointiin erikoistunut yhtiö. MosaicMill puolestaan kehitti metsien inventointia dronejen avulla. (Afy 2022.)

Opinnäytetyössä selvitetään vastaukset seuraaviin kysymyksiin:

- Kuinka hyvin dronekuvista tunnistetaan yksittäiset puut?
- Kuinka tarkasti puustotunnusten estimointi onnistui?
- Kuinka paljon puustotunnusten tarkkuutta oli saatu parannettua päivitettyssä aineistossa?
- Kuinka suuren lisähyödyn kalibroitikertoimien avulla lisätyt aliskasvospuut tuovat inventointitulokseen?

4 Aineistot

4.1 Maastoinventointi


Tutkimusalue sijaitsi Keski-Ruotsissa. Se koostui mänty- ja kuusimetsistä, joissa kasvoi lehtipuita sekapuuna. Ne vaihtelivat kehitysluokissa 02–04. Tutkimusalueen metsät olivat talousmetsää, sillä niiden pääasiallinen tarkoitus oli puuntuotanto ja siellä oli tehty metsätaloudentoimenpiteitä. Alue ei kuitenkaan vastannut täysin suomalaista käsitystä talousmetsästä, sillä harvennusrästejä oli havaittavissa enemmän. Myös muutamat 02-kehitysluokan kuvioista olivat todella tiheitä, josta pystyi päättelemään, että taimikonharvennusta ei ollut toteutettu.

Maastoinventointi toteutettiin syys-lokakuun aikana. Koealoilta mitattiin läpimitta jokaisesta puusta, joka oli yli 5 cm rinnankorkeudelta. Lisäksi kirjattiin puulaji ja puun luokka. Puun luokkia olivat normaali, pituuskoepuu, kallellaan oleva puu, katkennut elävä puu, poikkeava pituus-läpimittasuhte, kuollut puu, pystykanto sekä kaatunut puu. Jokaiseen läpimittaluokkaan mitattiin pituuskoepuita. Pituus mitattiin kaikista aliskasvospuista sekä puista, joiden luokka oli muu kuin normaali. Lisäksi mitattiin myös kaatuneet puut. Koealan tietoihin tuli myös tiedot kasvupaikasta, kehitysluokasta ja huomiot säätilasta, mikäli se voisi heikentää GPS-paikannuksen tarkkuutta. (kuva 7)



Kuva 7. Jokainen puu merkittiin spraymaalilla, jotta mitaajien työ helpottui. (Kuva: Karte.)

Koealat olivat puukarttakoealoja, eli niillä ei ollut kiinteää pinta-alaa. Puuston suuruuden mukaan niiden sivun pituus vaihteli 22–27 m:n välillä. Koealan rajauksessa pyrittiin mukailemaan aukkoja, jotta koealat olisivat helppo erottaa ilmakuvausta (kuva 8). Tyypillisesti koealaan mahtui 100–200 puuta.



Kuva 8. Esimerkki maastokoealan rajauksesta. Sinisellä koealan rajat ja keltaisella mitatut puut.

Mittavälineinä oli elektroniset mittasakset, 16 tukiasemaa, GPS-laitteisto ja Vertex -korkeusmittari. Elektronisilla mittasaksilla mitattiin rinnankorkeusläpimitta ja kirjattiin puukohtaiset tiedot. Mittasakset olivat yhteydessä matkapuhelinsovellukseen, jossa pystyi selaamaan mitattuja puita. Puiden tarkat sijainnit saatiin määritettyä koealalle sijoitettujen 16 tukiaseman avulla (kuva 9). Tukiasemat olivat yhteydessä mittasaksiin, jotka mittasivat kunkin puun etäisyydet niihin. Siten puiden sijainnit saatiin paikannettua paikalliskoordinaatistoon. GPS-laitteistolla mitattiin tarkat sijainnit neljästä koealan kulmasta. GPS-masto täytyi sijoittaa avoimelle kohdalle, jotta se sai yhteyden riittävän moneen satelliittiin. Myös GPS-masto mitattiin mittasaksilla, jotta yksittäisten puiden sijainnit voitiin siirtää valtakunnalliseen koordinaatistoon. Tällä menetelmällä yksittäisten puiden sijainti saadaan määritettyä alle 0,5 m:n tarkkuudella (Antinluoma & Rahkola 2022).



Kuva 9. Tukiasemat kiinnitettiin oksiin tai ohuisiin runkoihin. (Kuva: Karte.)

Maastoinventointi toimii tutkimuksessa referenssiaineistona. Siihen verrataan dronekuvista estimoituja puustotunnuksia ja selvitetään niiden tarkkuus. Maastoninventoinnissa kaikkein tarkin mitta on rinnankorkeusläpimitta. Pituusmittauksessa käytettävä Vertex on luotettava, mutta sumuinen sää tai säätilan muuttuminen saattaa vaikuttaa mittaustuloksiin. Tästä syystä Vertex kalibrointiin ennen jokaista koealaa. Koealan tietoihin kirjattiin myös huomio sateisesta ja sumuisesta säästä. Maastoinventointia varten mittaajille järjestettiin koulutuspäivä. Maastossa liikuttiin 2 hengen ryhmissä, joka helpotti mittausten järjestelmällistä toteuttamista.

4.2 Dronekuvaukset

Metsälinkki Oy kuvasi tutkimusalueen 9.-12.8.2022. Kuvattua pinta-alaa tuli yhteensä 415 ha. Sää oli kuvausolosuhteiltaan hyvä, aurinkoinen ja heikkotuulinen. Lentokorkeus oli 120 m. Lennot toteutettiin avoimessa kategoriassa, sillä alueella ei ollut asutusta. Kuvauksiin käytettiin Nordic Drones Oy:n valmistamaa

maanmittausdronea. Mittalaitteistoon kuului sekä RGB- että multispektrikamera. RGB-kameran geometrinen resoluutio oli 2,4 cm ja multispektrikameran 8 cm. Dronessa oli myös PPK-satelliittipaikannusjärjestelmä.

4.3 Aineistojen analyysi

Inventointidatasta tuotettiin yhteensä kuusi aineistoa. Datan prosessoinnin on tehnyt AFRY.

Maastoinventoinnista saatiin kaksi aineistoa, koealan tasolta ja yksittäisen puun tasolta. Koealantasolla keskiläpimitta ja keskipituus ovat painotettu pohjanpinta-alalla. Yksittäisen puun tasolla saatiin läpimitta ja tarkat koordinaatit koealan jokaisesta puusta. Pituuskoepuille on mitattu pituus ja muille puille AFRY on mallintanut sen.

Dronella kuvatusta alueesta rajattiin maastokoealoja vastaavat alueet. Niistä saatiin kaksi aineistoa, koealatason ja yksittäisen puun tason aineistot, joita verrattiin maastomittauksiin. Yksittäisen puun tasolla jokaiselle puulle mitattiin pituus ja latvuksen leveys. Puiden pituudet saatiin dronekuvasta tulkitun latvuskorkeuden ja laserkeilatun maastomallin erotuksena. AFRY mallinsi läpimitan ja tulkitsee puulajin omilla menetelmillään. Droneaineistoista on ensimmäinen versio (10.3.2023). Sen puustotunnusten laskentamenetelmiä muutettiin ja saatiin päivitetty versio (13.4.2023).

Droneaineistojen puuhakualgoritmit oli säädetty välttämään ylimääräisten puiden syntymistä. Piiloon jääneitä puita voi lisätä jälkikäteen esimerkiksi laserkeilausaineiston tai kalibrointikertoimien avulla. Kalibrointikertoimet saadaan maastokoealojen avulla, kun niistä määritetään pituusluokittain runkoluvun kertoimet. Kuudes aineisto on lisäpuuaineisto. Se saatiin, kun päivitettyyn aineistoon (13.4.) lisättiin lisäpuita kalibrointikertoimien avulla.

Kvantitatiivisessa, eli määrällisessä tutkimuksessa aineistoon tehdään tilastotieteellinen analyysi, jonka pohjalta pyritään tekemään yleistyksiä. Taustaoletuksena on se, että tutkimuksessa saavutetaan yksilöstä riippumaton tieto. Kvantitatiivisen tutkimuksen avulla voi selvittää asioiden syy-seuraussuhteita, löytää uusia näkökulmia ja määrittää keskeisiä malleja ja luokkia. (Vilka. 2021, 135–149.) Tämä opinnäytetyö on kvantitatiivinen tutkimus. Työssä tarkasteltiin 49 koealaa ja niiden puustotunnuksia vertailtiin eri inventointimenetelmillä kerättyjen aineistojen välillä.

Yksittäiset puut kattavista aineistoista selvitettiin dronen kyky tunnistaa puut. Aineistot ovat GeoPackage -tiedostoja ja niitä tarkasteltiin QGis -sovelluksen avulla. Maastoaineistosta ei otettu huomioon pystykantoja, lisäpituuskoepuita eikä kaatuneita puita, koska näitä ei ole tarkoitus tunnistaa dronekuvista. Molemista aineistoista tarkasteltiin puita, joiden rinnankorkeusläpimitta oli yli 5 cm. Aineistot siirrettiin Excel -ohjelmistoon ja puista muodostettiin runkolukusarjat. Runkolukusarjoista voitiin tarkastella, kuinka suuri osuus puista saatiin tunnistettua läpimittaluokittain. Kuolleet puut tarkasteltiin erikseen ja niistä muodostettiin oma runkolukusarja.

Puulajien tunnistamisen onnistumista tarkasteltiin siirtämällä puulajitiedot Excel -ohjelmistoon. Puulajikohtaisesti laskettiin tunnistettujen puiden määrä dronekuvista ja sitä verrattiin maastomittauksiin. Myös puulajikohtaiset runkolukusarjat tehtiin.

Koealakohtaisista aineistoista selvitettiin pohjapinta-alan, keskiläpimitan, keskipituuden, runkoluvun ja keskitilavuuden tarkkuus. Droneaineistosta saadut tunnuksat vähennettiin referenssiaineistona toimivista maastomittauksista ja virheistä laskettiin keskiarvo. Tätä kutsutaan systemaattiseksi virheeksi.

Systemaattinen virhe eli harha (BIAS) johtuu käytettävästä mittalaitteesta tai -menetelmästä ja se voidaan havaita, kun mittaus toistetaan eri tavalla. Systemaattisen virheen suuruus saadaan selville, kun lasketaan virheiden summa. Mikäli virheiden summa on nolla, niin estimaatti on harhaton. (Taylor 1997, 94–

119.) Harhaa käytetään kuvaamaan tunnusten välisien virheiden suuntaa. Se on laskettu sekä absoluuttisena että suhteellisena käyttäen seuraavia kaavoja:

$$BIAS = \frac{\sum(maasto - drone)}{koealojen\ määrä}$$

$$BIAS\% = \frac{BIAS}{maastoreferenssin\ keskiarvo} \times 100\%$$

Keskineliövirheen neliöjuuri, RMSE (root-mean-square error), kuvaa tunnusten välistä tarkkuutta. Se kertoo sen, kuinka estimaattien arvot ovat keskittyneet todellisten arvojen ympärille. Mitä pienempi RMSE:n arvo on, sitä tarkempi estimaatti on. RMSE laskettiin sekä absoluuttisena että suhteellisena käyttäen seuraavia kaavoja:

$$RMSE = \sqrt{\frac{\sum(maasto - drone)^2}{koealojen\ määrä}}$$

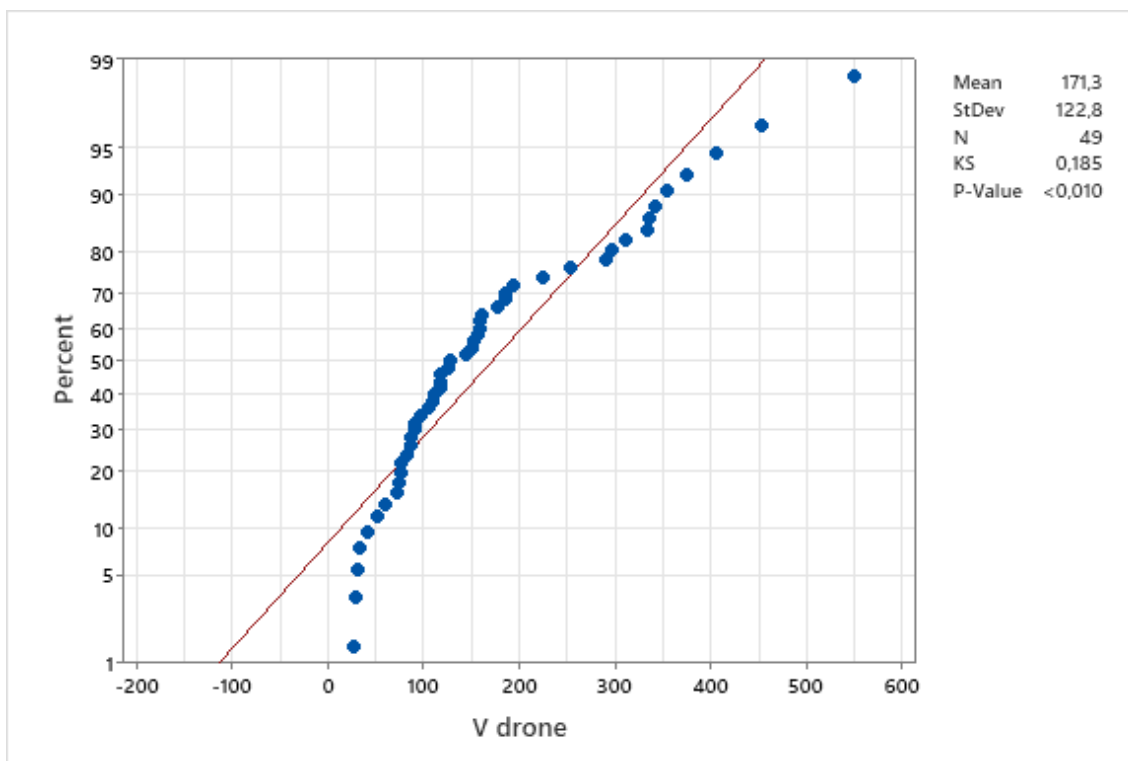
$$RMSE\% = \frac{RMSE}{maastoreferenssin\ keskiarvo} \times 100\%$$

Regressioanalyysissä havainnollistetaan kahden aineiston riippuvuutta toisistaan. Tavoitteena on muodostaa niiden lineaarista yhteyttä kuvaava malli ja selvittää miten niiden muuttujat ovat yhteydessä keskenään. Regressiomalli saadaan, kun aineisosta tehdään Excelillä sirontakuviot ja siihen lisätään trendiviiva, sen yhtälö ja selityskerroin R^2 . Sirontakuviota voidaan kutsua myös hajontakuvioksi tai korrelaatiodiagrammiksi. Mallin parametrit estimoidaan pienimmän neliösumman menetelmällä. Trendiviivan yhtälöä kutsutaan regressioyhtälöksi ja se kertoo muuttujien yhteyden voimakkuutta ja suuntaa. Sen avulla voidaan ratkaista y , kun x tunnetaan ja toisinpäin. Selityskerroin R^2 kertoo sen, kuinka suuri osuus y :n vaihtelusta voidaan selittää x :n arvojen vaihtelulla. Mitä suurempi selityskerroin on, sitä lähemmäs havainnot sijoittuvat regressiosuoraan ja sitä

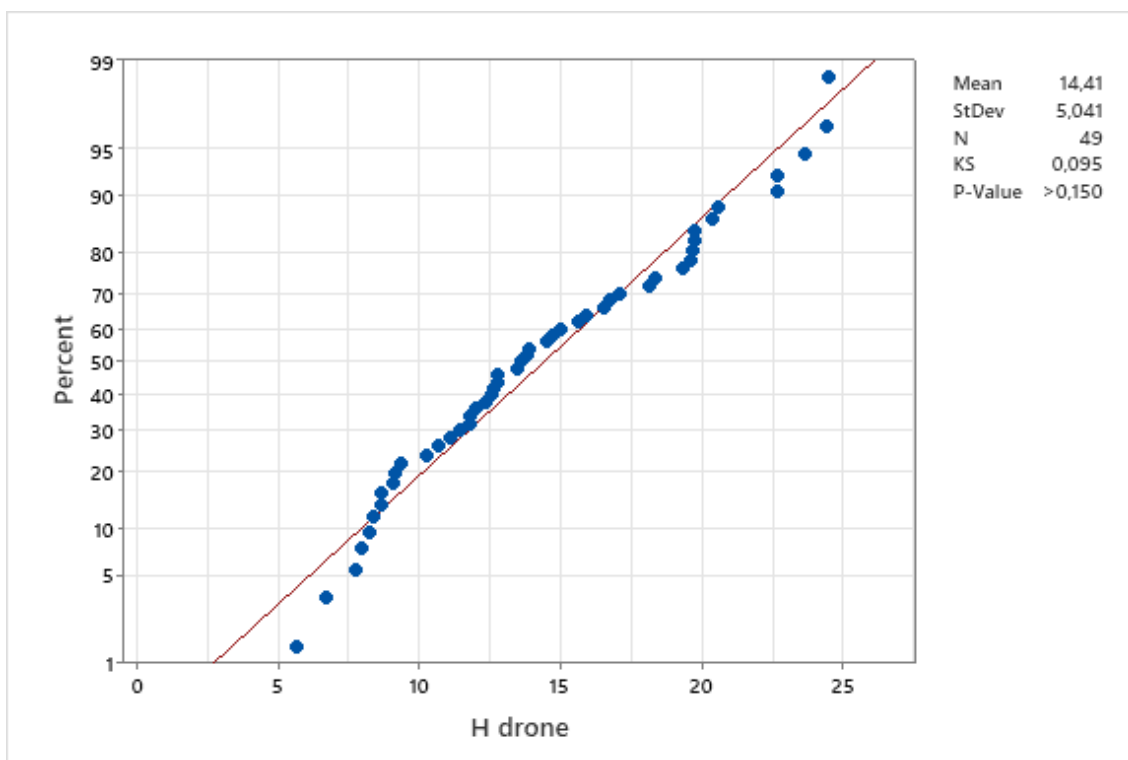
parempi malli on. (Tähtinen, Laakkonen & Broberg 2020, 194–212; Taanila 2020; Taanila 2022).

Maasto- ja droneaineistoille tehtiin lineaarinen regressioanalyysi. Regressiosuoran kaavalla voidaan laskea koealan puustotunnukset sijoittamalla droneinventoinnista tulkittu arvo muuttujan x paikalle. Selityskerroin R^2 kertoo sen, kuinka hyvin droneaineisto selittää maastoaineiston vaihtelua. Selityskertoimen riittävä suuruus on määriteltävä tutkimuskohtaisesti. Yhteiskunta- ja käyttäytymistieteissä selityskertoimen arvot liikkuvat yleensä 0,2 alapuolella (Tähtinen ym. 2020, 194–212). Tässä tutkimuksessa tarkastellaan teknologiaan perustuvaa menetelmää, jonka tulosta on tarkoitus pystyä hyödyntämään strategisessa päätöksenteossa. Siksi riittävän tarkkuuden osoittavaksi selityskertoimeksi valettiin 0,7 taso. Samaa raja-arvoa on käyttänyt tutkimuksessaan myös Puliti ym. (2015).

Kahden ryhmän keskiarvoja voidaan vertailla T- ja U-testeillä. T-testi on parametrisen testi ja sen käyttö edellyttää sitä, että aineisto on normaalijakautunut. Mann-Whitneyn U-testi on epäparametrinen ja sitä voidaan käyttää silloin, kun T-testin vaatimukset eivät täyty. (Tähtinen ym. 2020, 120–137.) Aineiston normaalijakautuneisuus tutkittiin Minitab -ohjelmistolla (kuviot 1 ja 2). Normaalijakautuneita olivat koko alueen keskiläpimitan ja -pituuden aineistot sekä kuusen pituuden aineisto. Loput eivät olleet normaalijakautuneita. Koealan puustotunnusten vertailuun käytettiin siis sekä T- että U-testiä.



Kuvio 1. Dronen tilavuusaineisto koko alueelta. Jakauma ei ole normaalijakautunut, sillä p-arvo on alle 0,05.



Kuvio 2. Dronen keskipituusaineisto koko alueelta. Jakauma on normaalijakautunut, sillä p-arvo on suurempi kuin 0,05.

T- ja U-testeistä saatua p-arvoa verrattiin merkitsevyytasoon ja saatiin selville vastaako nollahypoteesi aineistoa. Mitä lähempänä p-arvo on nollaa, sitä heikommin aineisto vastaa nollahypoteesia. Yleisesti merkitsevyytasona käytetään 0,05: n tasoa, eli sitä pienemmät p-arvot kertovat tilastollisesta merkitsevyydestä. (Tähtinen ym. 2020, 40–44). Tutkimuksen nollahypoteesi on H_0 : ”drone- ja maastomittaukset eivät poikkea toisistaan” ja vastahypoteesi on H_1 : ”drone- ja maastomittaukset poikkeavat toisistaan”. Tässä tutkimuksessa merkitsevyytasona käytettiin 0,05 tasoa ja jos p-arvot alittavat sen, nollahypoteesi hylätään. Siinä tilanteessa drone- ja maastomittaukset poikkeaisivat tilastollisesti merkitsevästi toisistaan. Merkitsevyytaso on todennäköisyyden sille, että tutkija hylkää nollahypoteesin virheellisesti (Helve, Komulainen, Pyörälä, Merenmies & Holopainen. 2014). Tässä tutkimuksessa virheen todennäköisyys on siis 5 %.

5 Tulokset


5.1 Puiden tunnistaminen koaloilta

5.1.1 Mänty-kuusisekametsä


Koeala 37 on mänty-kuusisekametsää kuivahkolla kankaalla (kuva 10). RGB-kuvassa punaiset renkaat merkitsevät dronekuvista tunnistettuja puita ja keltaiset pisteet ovat maastossa mitattuja (kuva 11). Voidaan havaita, että suuret puut drone on tunnistanut, mutta niiden ympärillä olevia pienempiä puita on jäänyt havaitsematta. Pienemmät puut ovat jääneet suurempien latvuksien alle. Kuvassa 12 on koealasta lähi-infrakuva.



Kuva 10. Puustoa koelalalta 37. (Kuva: Karte.)



Kuva 11. Ero maasto- ja droneinventoinnilla havaittujen puiden välillä. Keltaiset pisteet maastossa mitattuja ja punaiset renkaat dronekuvista tulkit-tuja.



Kuva 12. Puulajeja lähi-infrakuvasta. Maastossa mitatut merkitty palloina ja dronekuvista tulkitut renkaina. Mänty (sininen), kuusi (vihreä) ja lehtipuut (pinkki).


Lähi-infrakuvasta nähdään eri väreillä puulajit, jotka on tunnistettu dronekuvasta. Mänty näkyy sinipunaisena ja kuusi keltaruskeana. Männyistä tunnistettiin 76 % ja kuusista 55 %. Osa puista on jäänyt latvuksien alle piiloon ja muutama oli tulkittu virheellisesti lehtipuuksi.

5.1.2 Elävät ja kuolleet kuuset

Koeala 20 on tuoreen kankaan kuusikko, jossa kasvaa sekapuuna mäntyjä, lehtikuusia ja koivuja (kuva 13). Koealalla oli myös muutamia kuolleita kuusia, jotka näkyvät turkooseina lähi-infrakuvassa (Kuva 14). Lehtipuut näkyvät siinä punertavina ja koealan länsireunan suuri rauduskoivu on tunnistettu oikein. Koealalta tunnistettiin mäntyjä 15 kpl, vaikka todellisuudessa niitä oli vain 2 kpl. Lehtikuusia ei ollut tarkoitus tunnistaa erikseen dronekuvista ja ne on luokiteltu kuusiksi.



Kuva 13. Koeala 20. (Kuva: Karte.)



Kuva 14. Dronen multispektrikameralla otettu kuva koealasta 20. Renkaat dronekuvista ja pallot maastossa tunnistettuja puita. Koealalla mäntyjä (sininen), kuusia (vihreä), lehtikuusi (keltainen), lehtipuita (pinkki) ja kuolleita puita (punainen). Maastossa mitatut kaatuneet puut (valkoinen).


Koealaa tarkasteltaessa voidaan havaita, että yksi kuolleista puista oli kaatunut drone- ja maastoinventoinnin välisenä aikana. Dronekuvista oli tunnistettu koealan lounaisreunan kuusia mänyiksi. Ne kuuset näkyvät väri-infrakuvassa muita sinisempinä. Koealan kuolleista puista oli tunnistettu 5 kpl ja niitä oli yhteensä 11 kpl. Niistä tunnistettiin siis 45 %.

5.1.3 Harvennettu männikkö

Koeala 71 on kuivahkon kankaan puhdas männikkö, joka oli harvennettu (kuva 15). Puut erottuivat selkeästi toisistaan dronekuvissa ja koealan elävistä puista 98 % tunnistettiin (kuva 16).



Kuva 15. Koeala 71 (Kuva: Karte.)



Kuva 16. Dronekuva koealasta 71. Punaiset renkaat ovat dronekuvista ja keltaiset pallot maastossa mitattuja puita.


Tämän koealan inventointi dronekuvien avulla onnistui todella hyvin. Koealalla ei ollut piiloon jäävää aliskasvosta, ja siksi lähes kaikki puut saatiin tunnistettua. Myös puulajin tunnistaminen onnistui hyvin. Koealalla oli 96 mäntyä ja dronekuvien perusteella niistä tulkittiin 89 oikein. 5 puuta tulkittiin virheellisesti kuusiksi tai lehtipuiksi. Koealalla oli 2 pientä kuollutta puuta. Ne jäivät havaitsematta dronekuvista.

5.1.4 Kaksijakoinen metsä

Koeala 76 oli kaksijakoinen metsä lehtomaisella kankaalla, jossa kasvoi rauduskoivuja ja mäntyjä ylispuina ja kuusia aliskasvoksena (kuva 17). Kuva 18 on lähi-infrakuva koealasta, johon on merkitty dronesta ja maastossa mitatut puut.



Kuva 17. Puustoa koealalta 76. (Kuva: Karte.)




Kuva 18. Koealalla 76 on mäntyjä (sininen), kuusia (vihreä) ja lehtipuita (pinkki).

Kaksijakoinen metsä on haasteellinen inventoida dronekuvista. Ylispuina kasvavien rauduskoivujen alle jää puuta piiloon. Koealan 76 puustosta havaittiin alle puolet, 42 %. Aliskasvos koostui pääasiassa kuusista, ja niiden määrästä havaittiin vain 15 %.

5.2 Runkolukusarjat

5.2.1 Kaikki puulajit

Maastossa mitattiin yhteensä 5 042 rinnankorkeusläpimitaltaan yli 5 cm:n paksuista elävää puuta. Dronekuvista niitä tulkittiin vastaavasti 3 439. Dronekuvista jäi siis havaitsematta 1 603 puuta, mikä on 32 % kokonaisrunkoluvusta. Tutkimusalueen puut jaettiin 5 cm:n läpimittaluokkiin, alkaen 5 cm rinnankorkeusläpimitasta. Kuvio 3 nähdään, kuinka monta runkoa dronen ja maastomittausten avulla mitattiin kussakin läpimittaluokassa.




Kuvio 3. Tutkimusalueen runkolukusarja.

Läpimitaltaan 5–10 cm:n puita oli tutkimusalueella eniten ja dronekuvista niistä tunnistettiin 56 %. 10–15 cm:n ja 15–20 cm:n puista tunnistettiin 75 % ja 76 %. Parhaiten tunnistettiin 20–25 cm:n puut, 84 %. 25–30 cm:n puista tunnistettiin 74 % ja 30–35 cm:n puista 57 %. 35–40 cm:n puista tunnistettiin 47 %. Yli 40 cm:n puista drone tunnisti enää 3 %. Pienimpiä ja suurimpia puita jäi siis suhteessa eniten havaitsematta.

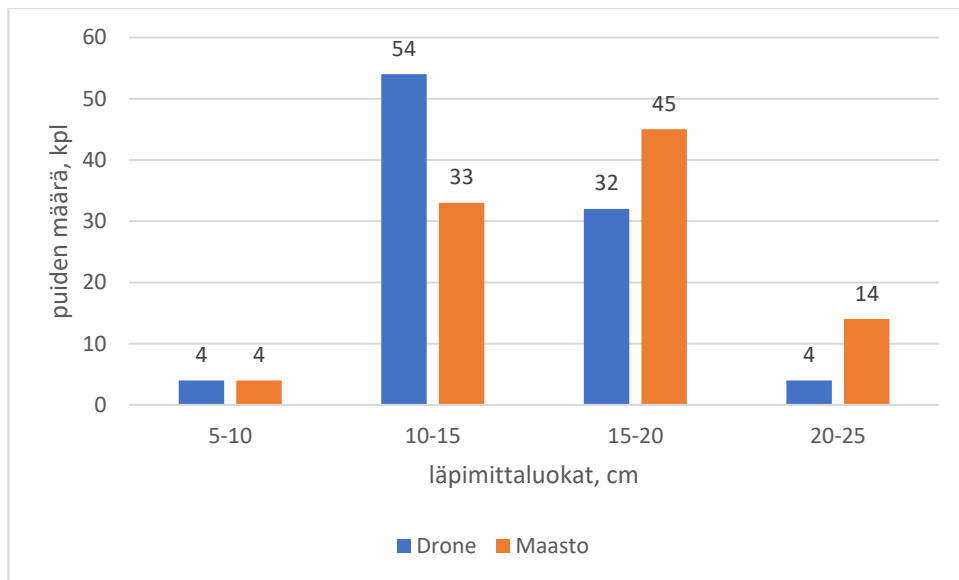
5.2.2 Mänty

Mänty oli tutkimusalueen toinen pääpuulaji. Puhtaat männiköt kasvavat harvassa ja sekametsissä mänty ei kasva aliskasvoksena. Valolajina niiden latvat ovat lähes aina nähtävillä. Siitä johtuu, että mäntyjen tunnistaminen onnistui parhaiten ja niistä tunnistettiin 95 %. Runkolukusarjasta voidaan havaita, että erot läpimittaluokkien välillä ovat pieniä (kuvio 4).



Kuvio 4. Runkolukusarja tutkimusalueen mäennyistä.

Männyt havaitaan siis hyvällä tarkkuudella, mutta runkolukusarjasta voidaan havaita, että maastomittauksiin verrattuna havainnot painottuvat pienempiin läpimittaluokkiin. Hyvänä esimerkkinä tästä aiemmin esitellyn koelan 71 runkolukusarja (kuvio 5).




Kuvio 5. Koealan 71 runkolukusarja.

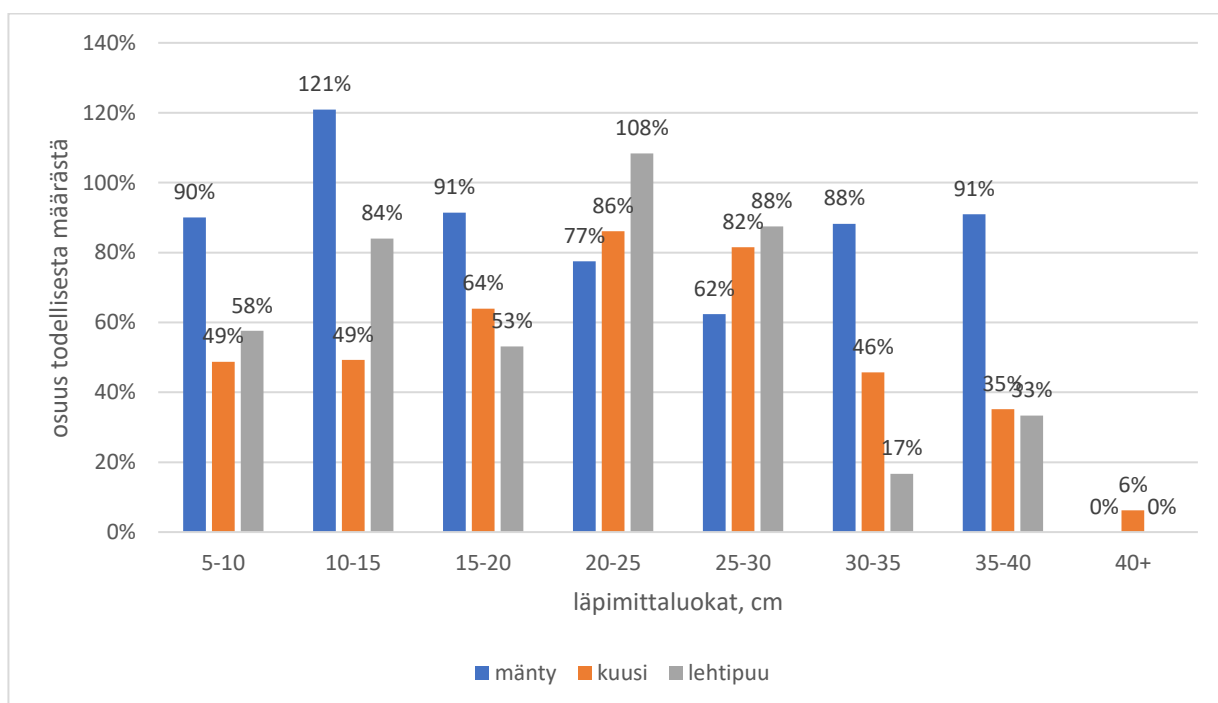
Droneinventoinnin perusteella koealalla olisi eniten 10–15 cm läpimitaltaan olevia puita. Niitä on tulkittu 21 enemmän, kuin maastossa on mitattu. Kyseiset puut on tulkittu sinne suuremmista läpimittaluokista.

5.2.3 Kuusi

Tutkimusalueen toinen pääpuulaji oli kuusi. Kuusista tunnistettiin 55 %. Kuusikot voivat kasvaa hyvinkin tiheinä ja etenkin tupaat sekä aliskasvokset aiheuttavat ongelmia puiden havaitsemiseen. Valtapuina kuusia tunnistettiin paremmin, mutta pienet aliskasvoskuuset heikensivät kuusien tunnistamisen onnistumista kokonaisuudessaan. Kuusten runkolukusarjasta voidaan havaita, että juuri aliskasvoskuusia, läpimitaltaan 5–10 cm, oli eniten ja niitä jäi myös eniten tunnistamatta (kuvio 6). Kuvio 7 voidaan vertailla puiden tunnistamisen onnistumista puulajeittain eri läpimittaluokissa.

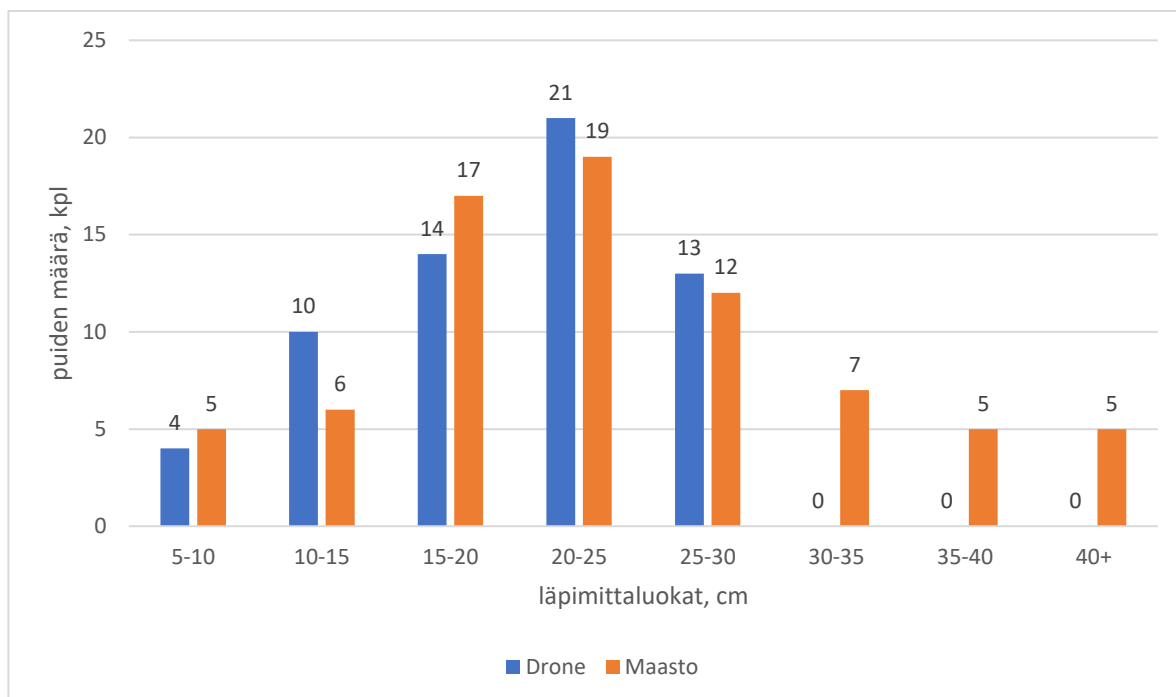


Kuvio 6. Tutkimusalueen kuusten runkolukusarja.



Kuvio 7. Tunnistettujen puiden osuus todellisesta määrästä.

Läpimitaltaan 20–30 cm kuusista tunnistetaan 84 %. Sen jälkeen tunnistamisprosentti tippuu ja läpimitaltaan 30–40 cm puista tunnistetaan enää 40 %. Esimerkkinä tällaisesta tilanteesta toimii aiemmin esitelty koeala 20 (kuvio 8).

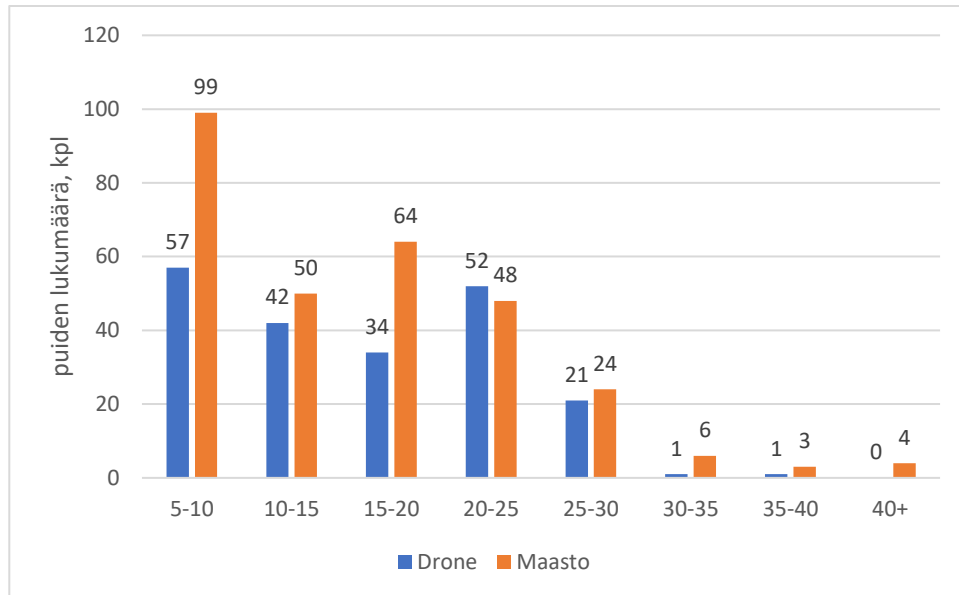


Kuvio 8. Runkolukusarja koealalta 20.


Tämä on sama ilmiö, mikä jo aiemmin todettiin männyillä, mutta se ilmenee kuusilla vielä vahvemmin. Suuret kuuset kyllä havaitaan, mutta ne tulkitaan liian pieniksi ja tämän voisi olettaa johtavan keskiläpimitan ja -tilavuuden aliarvioon.

5.2.4 Lehtipuu

Tutkimusalueella ei ollut puhtaita lehtipuumetsiköitä, vaan ne kasvoivat seka-puuna mänty- ja kuusimetsissä. Siitä johtuu suurien yksilöiden pieni määrä, jonka voi havaita lehtipuiden runkolukusarjasta (kuvio 9). Lehtipuista tunnistettiin 70 %. Vaikka ne ovat valolajeja, pienet yksilöt voivat jäädä dronekuvissa valtapuiden alle piiloon tai niiden varjoon, mikä heikentää dronen kykyä tunnistaa ne. Lehtipuut ovat taipuisia ja esimerkiksi lumituhot voivat taivuttaa niitä siten, että puun latva on eri paikassa kuin sen tyvi. Tällaisessa tilanteessa drone tunnistaa puun sijainnin väärään kohtaan. Näin on käynyt esimerkiksi koealalla 23 (kuva 19).




Kuvio 9. Tutkimusalueen lehtipuiden runkolukusarja.



Kuva 19. Kallellaan kasvavia hieskoivuja koealalla 23. Dronekuvista tulkitut puut ovat merkitty renkaalla ja maastossa mitatut pallolla.

Kasvaessaan metsikön vallapuina lehtipuut muodostavat tiheän latvuserroksen, jonka alla kasvavaa aliskasvosta on mahdotonta havaita dronekuvista. Tämä havaittiin myös aiemmin esitellyssä koealassa 76, jonka runkolukusarja on kuvio 10.



Kuvio 10. Runkolukusarja koealalta 76.

Runkolukusarjasta havaitaan, että rinnankorkeusläpimitaltaan alle 15 cm puita ei tunnistettu lainkaan. Koealan pääpuulajista, rauduskoivusta, tunnistettiin 91 %. Tämä aiheuttaa haasteita eri-ikäisrakenteisen metsän inventointiin sekä ennakkoraivauksen tarpeen arviointiin dronekuvien pohjalta.

5.3 Puustotunnukset

Tutkimusalue koostui 49 koealasta, joiden pinta-ala oli yhteensä 4,04 ha. Siellä kasvoi yhteensä 822 m³ puuta. Siitä mäntyä oli 299 m³, kuusta 436 m³ ja lehtipuita 59 m³. Puusto painottui siis mänty- ja kuusimetsiin. Lehtipuita kasvoi sekapuuna ja yksittäisillä kuvioilla myös pääpuulajina. Taulukossa 3 on esitetty tutkimusalueen puustotunnukset keskitunnuksina. Käsiteltävä droneaineisto on 10.3.2023 versio ja sen mukaan alueella kasvoi 740 m³.

Tutkimusalue	G, m ² /ha	V, m ³ /ha	D, cm	H, m	N, kpl/ha
Maasto	26,4	203,7	20,3	14,8	1 320
Drone 10.3.	22,4	183,3	20,6	15,5	978

Taulukko 3. Puusto tutkimusalueella maasto- ja droneaineiston mukaan.

T- ja U-testien avulla selvitetiin, onko drone- ja maastoaineiston välillä tilastollisesti merkitsevää eroa. Nollahypoteesi on H_0 : ”drone- ja maastomittaukset eivät poikkea toisistaan” ja vastahypoteesi on H_1 : ”drone- ja maastomittaukset poikkeavat toisistaan”. Koko alueen aineistoista pohjanpinta-alalla, keskitilavuudella ja keskiläpimitalla nollahypoteesi jäi voimaan. Runkoluvun ja keskipituuden osalta vastahypoteesi astui voimaan. Nollahypoteesi jäi voimaan kaikissa männyjen ja lehtipuiden puustotunnuksissa. Kuusen keskipituudessa ja runkoluvussa aineistot poikkeavat tilastollisesti merkittävästi toisistaan ja vastahypoteesi astuu voimaan. Testien tuloksista voidaan päätellä, että kuusen tunnuksista johtuu myös koko alueen hypoteesien hylkääminen. (taulukko 4)

koko alue	T-testi	U-testi	männä	T-testi	U-testi	kuusi	T-testi	U-testi	lehti-puu	T-testi	U-testi
G		H_0	G		H_0	G		H_0	G		H_0
V		H_0	V		H_0	V		H_0	V		H_0
D	H_0		D		H_0	D		H_0	D		H_0
H	H_1		H		H_0	H	H_1		H		H_0
N		H_1	N		H_0	N		H_1	N		H_0

Taulukko 4. T- ja U-testien tulokset puustotunnuksittain sekä puulajeittain.

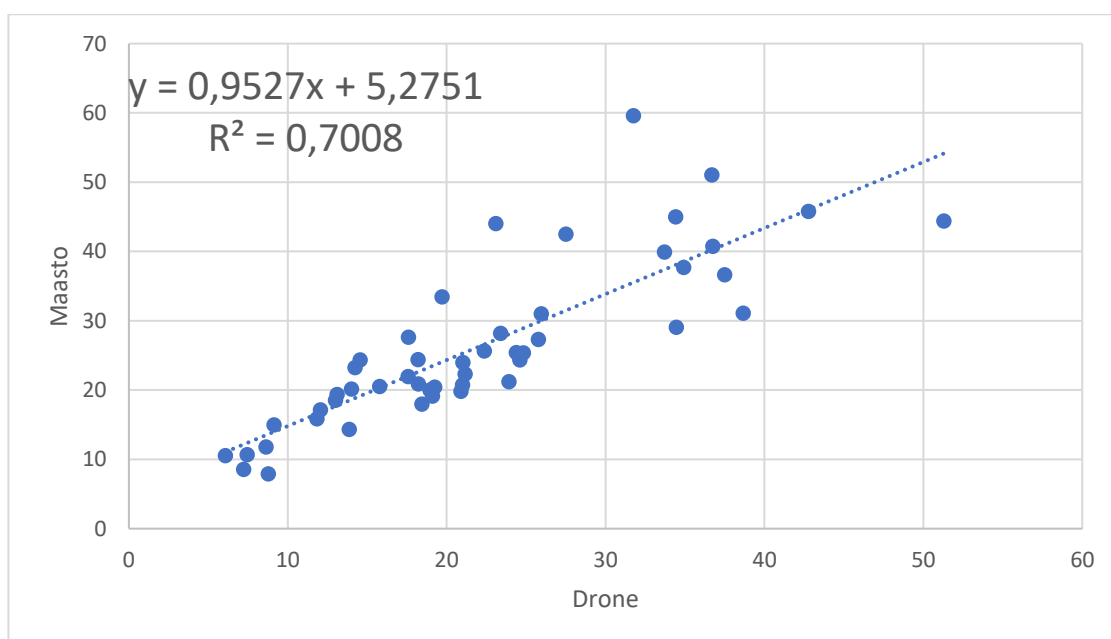
Perehdytään puustotunnusten tarkkuuksiin vielä tarkemmin ja lasketaan useampia tilastollisia tunnuslukuja niitä selittämään. Kaikki puustotunnukset ja niistä mitatut tunnusluvut esitetään taulukossa 5. Tunnusluvuista voidaan päätellä, että puustotunnusten harha (BIAS) on pieni, mutta tarkkuus (RMSE) on huonompi. Koko tutkimusalueella parhaiten onnistui keskipituuden (H) estimointi. Sen harha (BIAS) oli vain -0,44 m ja suhteellinen RMSE 10 %. Eniten haasteita tuotti runkoluvun (N) estimointi. Siinä harha oli 427,42 kpl/ha ja suhteellinen RMSE 42 %.

	G	V	D	H	N
BIAS	4,23	23,50	-0,41	-0,44	427,42
BIAS%	16 %	12 %	-2 %	-3 %	27 %
RMSE	7,60	58,62	3,31	1,35	676,84
RMSE%	29 %	30 %	17 %	10 %	42 %
R ²	0,70	0,82	0,82	0,96	0,60


Taulukko 5. Puustotunnusten tarkkuus tutkimusalueella droneaineisto 10.3.

Kaikista puustotunnuksista tehtiin sirontakuviot, joihin piirrettiin regressiosuora pienimmän neliösumman menetelmällä. Selityskerroin R² kertoo, kuinka hyvin droneaineisto selittää maastoaineiston vaihtelua. Pohjanpinta-alan (G) selityskerroin on 0,7 eli 70 % (kuvio 11). Tämä tarkoittaa sitä, että 70 % tapauksista on selitettävissä mallin avulla.


Keskitilavuuden ja keskiläpimitan selityskertoimet ovat 0,82 ja niiden pistekaaviot löytyvät kuviosta 12 ja 13. Keskipituuden pistekaaviosta voidaan havaita, että pisteet ovat keskittyneet parhaiten regressiosuoran ympärille muihin puustotunnuksiin verrattuna (kuvio 14). Keskipituuden malli on erittäin tarkka, ja sen selityskerroin on 0,96. Runkoluvun pistekaaviossa pisteet ovat puolestaan hajallaan ja selityskertoimessa päästään 0,60:n tasolle (kuvio 15).




Kuvio 11. Sirontakuvio ja regressiosuora tutkimusalueen koalojen pohjanpinta-aloista.




Kuvio 12. Sirontakuvio ja regressiosuora tutkimusalueen koalojen keskitilavuuksista.



Kuvio 13. Sirontakuvio ja regressiosuora tutkimusalueen koalojen keskiläpimi-toista.



Kuvio 14. Sirontakuvio ja regressiosuora tutkimusalueen koalojen keskipituuksista.



Kuvio 15. Sirontakuvio ja regressiosuora tutkimusalueen koalojen runkoluvuista.


Puulajeista tarkimmat keskitunnukset saatiin määritettyä männylle (taulukko 6). Pohjanpinta-alan (G), keskiläpimitan (D) ja keskipituuden (H) suhteelliset harhat (BIAS%) olivat alle 6 prosenttiyksikön sisällä. Keskipituuden (H) estimointi onnistui näistä parhaiten, sillä sen BIAS% oli 5,4 ja RMSE% vain 10 %. Muihin

puulajeihin verrattuna runkoluvun (N) määrittäminen oli myös tarkempaa. Kaikilla paitsi keskilämpötilalla (D) selityskertoimen on yli 0,7.

	G	V	D	H	N
BIAS	-0,09	-2,32	2,67	0,8	55,10
BIAS%	-1 %	-3 %	12 %	5.4 %	11 %
RMSE	3,90	37,81	6,23	1,55	244,75
RMSE%	41 %	54 %	28 %	10 %	50 %
R ²	0,77	0,76	0,58	0,92	0,89

Taulukko 6. Männyn puustotunnusten tarkkuus.

Kuviossa 16 on männyn koealakohtaisten keskitilavuuksien sirontakuvioiden ja regressiosuora. Regressiosuoran yhtälö on $y=0,6975x+19,56$. Jos dronekuvien avulla keskitilavuudeksi estimoidaan esimerkiksi 100 m²/ha, niin todellisuudessa tilavuus olisi 89,31 m²/ha. Malli toimii 76 % tapauksista. Pisteitä tarkasteltaessa voidaan havaita, että yksi poikkeama selkeästi muista. Dronen mukaan sillä koealalla männyn keskitilavuus olisi ollut noin 160 m³/ha, mutta maastomittausten mukaan ei juuri yhtään. Kyseessä on koeala 5, joka on 04 kehitysluokan kuusikko. Maastomittausten mukaan koealalla oli vain yksi mänty. Puulajitulkinnan virheet aiheuttavat siis poikkeamia puustotunnusten yhteneväisyyksiin, kun niitä tarkastellaan puulajeittain. Siitä seuraa heikommat arvot tarkkuutta ilmaisevissa tunnusluvuissa.

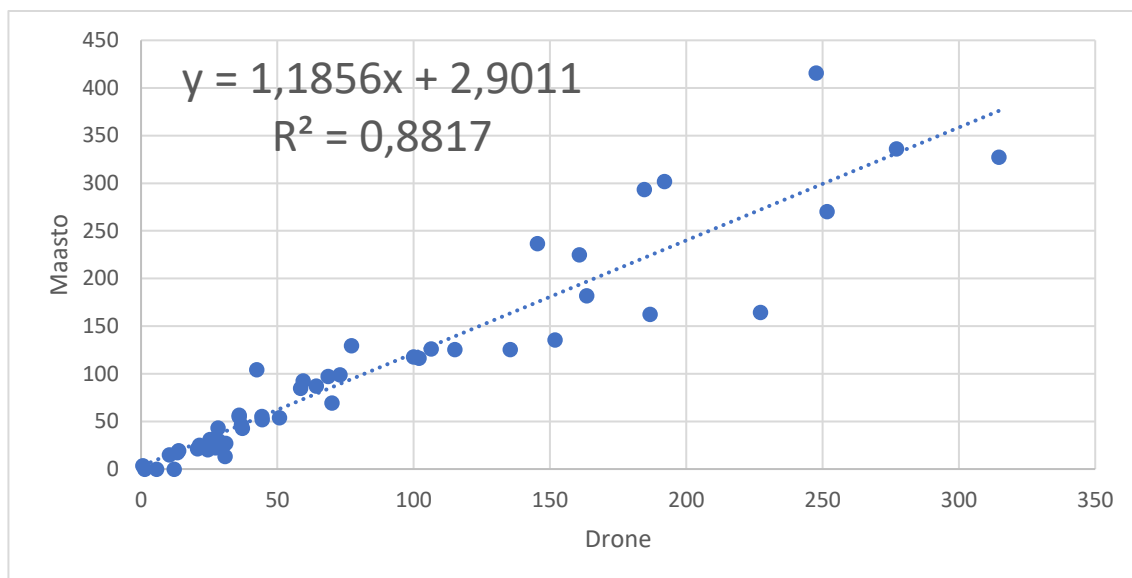


Kuvio 16. Männyn koealakohtaisten keskitilavuuksien sirontakuvio ja regressiosuora.

Kuusen puustotunnusten estimoinnin onnistumista voi tarkastella taulukosta 7. Keskiläpimitan (D) ja keskipituuden (H) suhteellinen harha (BIAS) on negatiivinen, eli drone tuottaa yliarvion maastoreferenssiaineistoon verrattuna. Keskitilavuuden osalta selityskerroin R^2 on parempi kuin männyllä. Kuvion 17 sirontakuviosta havaitaan, että pisteet asettuvat paremmin regressiosuoran ympärille.

	G	V	D	H	N
BIAS	3,11	18,75	-2,69	-1,86	302,78
BIAS%	22 %	18 %	-17 %	-15 %	32 %
RMSE	5,44	42,20	6,24	4,30	482,04
RMSE%	39 %	41 %	39 %	35 %	51 %
R^2	0,87	0,88	0,63	0,57	0,62

Taulukko 7. Kuusen puustotunnusten tarkkuus.




Kuvio 17. Kuusen koelakohtaisten keskitilavuuksien sirontakuviota ja regressiosuora.

Lehtipuun puustotunnusten estimointi onnistui heikoiten (taulukko 8). Runkoluvun (N) BIAS% on vain 2,6 %, mutta RMSE% on 106 %. Tästä voidaan päätellä, että virheiden etäisyydet ovat suuria, mutta ne kumoavat toisensa. Lehtipuun regressiomallia ei voida pitää luotettavana keskilämpötilan (D), keskipituuden (H) eikä runkoluvun (N) selityskertoimien perustella. Keskitilavuuksien sirontakuviosta havaitaan, että suurilla kuutiomäärillä lehtipuuta on vain yksittäisillä koealoilla (kuvio 18).


	G	V	D	H	N
BIAS	0,17	1,47	-2,11	-1,67	2,98
BIAS%	10 %	11 %	-23 %	-20 %	2.6 %
RMSE	1,66	9,82	7,35	6,46	86,62
RMSE%	71 %	70 %	79 %	76 %	106 %
R ²	0,90	0,92	0,48	0,36	0,57

Taulukko 8. Lehtipuun puustotunnusten tarkkuus.



Kuvio 18. Lehtipuiden koelakohtaisten keskitilavuuksien sirontakuvio ja regressiosuora.

Kuviossa 19 on lehtipuiden keskipituuksista tehty sirontakuvio. Siinä pisteet ovat hajallaan ja mallin selityskerroin onkin vain 0,35. Pysty- ja vaaka-akseleilla olevat pisteet kertovat siitä, että toisella inventointimenetelmällä lehtipuita on havaittu, mutta toisella ei lainkaan.

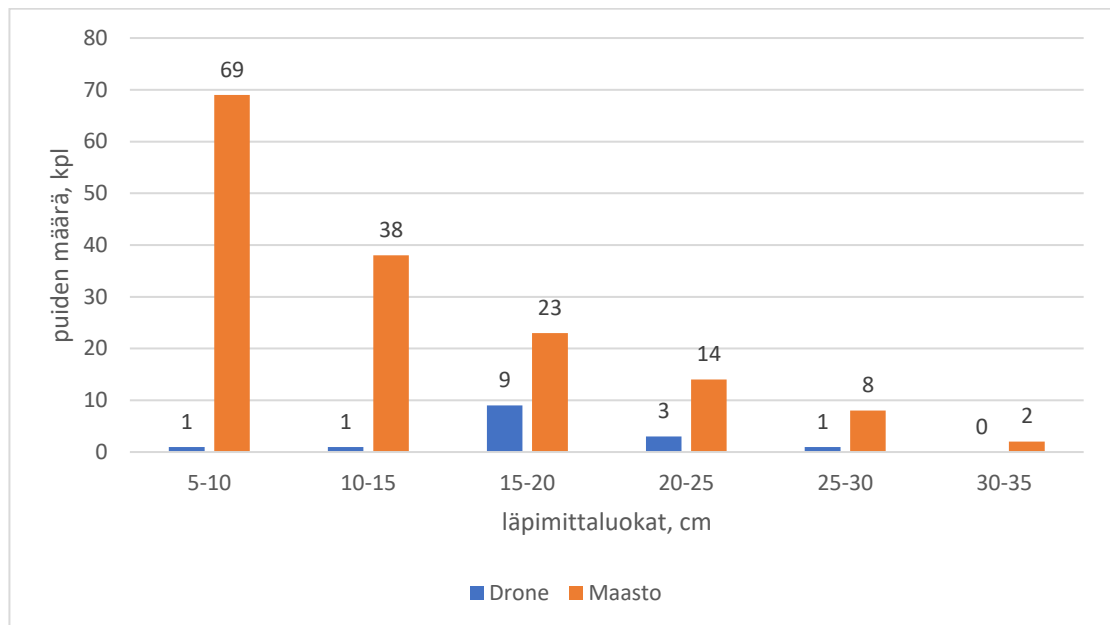


Kuvio 19. Lehtipuiden koelakohtaisten keskipituuksien sirontakuvio ja regressiosuora.

Lehtipuun määrä tutkimusalueella oli pieni ja sitä kasvoi lähinnä sekapuuna. Tämä on vaikeuttanut puustotunnusten tulkintaan, ja lehtipuun osalta otanta on pieni verrattuna mäntyyn ja kuuseen.

5.4 Kuolleet puut

Kuolleita puita oli tutkimusalueella 154, ja drone tunnisti niistä 15 eli noin 10 %. Kuolleiden puiden runkolukusarjasta (kuvio 20) havaitaan, että dronekuvista tulkittiin niissäkin paremmin suuria puita. Kuolleita puita oli tutkimusalueella yhteensä 28 m³.



Kuvio 20. Tutkimusalueen kuolleiden puiden runkolukusarja.

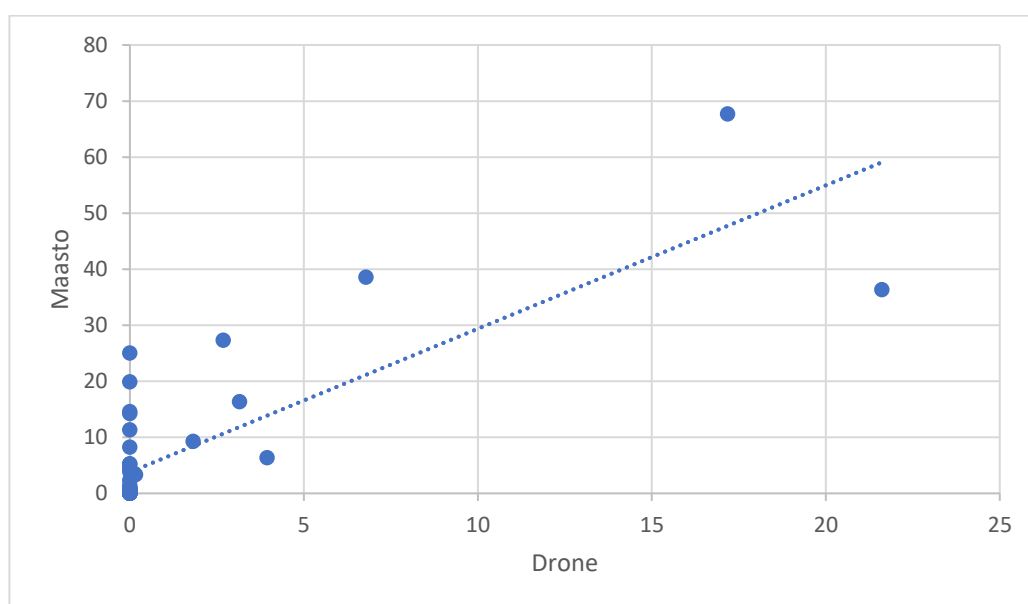
Kuolleiden puiden aineistot eivät olleet normaalisti jakautuneita, ja niiden keskiarvojen vertailemiseen käytettiin U-testiä. Kaikissa puustotunnuksissa vastahypoteesi astui voimaan ja todettiin, että aineistot poikkeavat tilastollisesti merkitsevästi toisistaan.

Puustotunnusten määrittäminen ei onnistunut riittävän tarkasti. Suhteellinen BIAS oli yli 50 % ja suhteellinen RMSE yli 100 % kaikissa puustotunnuksissa (taulukko 9). Kuolleiden puiden sirontakuvioista voi havaita, että pisteet eivät

muodosta lineaarista parvea regressiosuoran ympärille (kuvio 21). Tästä syystä regressioanalyysiä ei käytetä kuvaamaan puustotunnusten tarkkuutta.

Kuolleet puut	G	V	D	H	N
BIAS	1,04	5,61	6,38	2,86	66,56
BIAS%	88 %	83 %	68 %	53 %	93 %
RMSE	1,92	11,4	9,76	5,66	104,79
RMSE%	162 %	168 %	104 %	105 %	147 %

Taulukko 9. Kuolleiden puiden puustotunnusten tarkkuus.



Kuvio 21. Kuolleiden puiden koelakohtaisten keskitilavuuksien sirontakuvi ja regressiosuora.

Saman suuntaisia tuloksia saatiin tutkimuksessa, joka tehtiin Etelä-Suomessa sijaitsevalla tutkimusalueella. Maastomittausmenetelmä oli myös samankaltainen tämän opinnäytetyön kanssa. Eroja löytyi dronen laitteistosta ja kuvien tulkitsemiseen käytetyistä algoritmeista. Dronessa oli RGB-kamera ja hyperspektrikamera, joka kuvasi 22 kaistalla, RGB-kuvia käytettiin pistepilven luomiseen ja hyperspektrikuvista lisättiin malliin spektriset arvot (Saarinen, Vastaranta, Nasi, Rosnell, Hakala, Honkavaara, Wulder, Luoma, Tommaselli, Imai, Ribeiro, Guimaraes, Holopainen & Hyyppä 2018). Tutkimuksen tuloksia voi tarkastella taulukosta 10. Voidaan havaita, että tulokset ovat hyvin lähellä tämän opinnäytetyön tuloksia.

	V	N
BIAS%	98 %	99 %
RMSE%	165 %	147 %

Taulukko 10. Tutkimuksessa käytettiin useita menetelmiä. Tässä taulukossa esitetyt tulokset ovat saatu ITC (individual tree-crown approach) -menetelmällä. Tulkinnat tehtiin 3D-mallien ja spektriominaisuuksien perusteella. (Saarinen, ym. 2018.)

Kuolleiden puiden määrä tutkimusalueella on kuitenkin niin pieni, ettei sen perustella voi tehdä yleistyksiä tunnistamisen tarkkuudesta. Vaikka dronelennot ja maastomittaukset tehtiin muutaman kuukauden sisällä toisistaan, on mahdollista, että osa puista on ehtinyt kuolla niiden välisenä aikana. Tutkimusalueen inventointituloksen näkökulmasta epätarkkuudet kuolleisiin puihin liittyen eivät ole merkittäviä.

5.5 Päivitetty aineisto

Päivitetyn droneaineiston (13.4.) normaalijakautuneisuus testattiin ja ne olivat samankaltaiset, kuin aiemmillakin. Ainut poikkeus oli kuusen keskiläpimitan aineisto, joka oli normaalijakautunut. Aineistoihin suoritettiin T- ja U-testit normaalijakautuneisuusehdon mukaisesti (taulukko 11). Erona aiempiin tuloksiin on, että koko alueen pohjanpinta-alan (G) ja keskiläpimitan (D) maasto- ja droneaineistot poikkesivat tilastollisesti merkittävästi toisistaan. Keskipituuden (H) osalta kävi päinvastoin. Männyn ja lehtipuun osalta keskiläpimitan (D) aineistot poikkesivat tilastollisesti merkittävästi toisistaan. Kuusella tilanne pysyi samana aiempaan verrattuna.

koko alue	T- testi	U- testi	mänty	T- testi	U- testi	kuusi	T- testi	U- testi	lehti- puu	T- testi	U- testi
G		H ₁	G		H ₀	G		H ₀	G		H ₀
V		H ₀	V		H ₀	V		H ₀	V		H ₀
D	H ₁		D		H ₁	D	H ₀		D		H ₁
H	H ₀		H		H ₀	H	H ₁		H		H ₀
N		H ₁	N		H ₀	N		H ₁	N		H ₀

Taulukko 11. T- ja U-testien tulokset puustotunnuksittain sekä puulajeittain droneaineisto 13.4.

Dronekuvien tulkintaa oli saatu parannettua joidenkin puustotunnusten osalta. Päivitetyn aineiston mukaan alueen kokonaistilavuus on 660 m³. Taulukossa 12 esitetään tutkimusalueen puustotunnukset maastoaineistosta sekä molemmista dronekuviin pohjautuvista aineistoista. Puustotunnusten tarkkuutta kuvaavat tilastolliset tunnusluvut esitetään taulukossa 13.

Tutkimusalue	G, m ² /ha	V, m ³ /ha	D, cm	H, m	N, kpl/ha
Maasto	26,4	203,7	20,3	14,8	1 320
Drone 10.3.	22,4	183,3	20,6	15,5	978
Drone 13.4.	20,4	163,6	19,1	15,2	982

Taulukko 12. Puusto tutkimusalueella eri aineistojen mukaan.

	G	V	D	H	N
BIAS	6,13	41,46	1,00	-0,30	423,1
BIAS%	23	21	5	-2	27
RMSE	8,98	67,20	2,82	1,29	678,7
RMSE%	34	34	15	9	43
R ²	0,69	0,82	0,83	0,96	0,59

Taulukko 13. Päivitetyn aineiston puustotunnusten tarkkuus tutkimusalueella.

Päivitetystä aineistosta lasketun keskipituuden (H) tarkkuus parani. Sen BIAS oli pienentynyt 0,14 m:llä ja RMSE 0,06 m:llä. Keskiläpimitan (D) BIAS oli

aiemmassa aineistossa -0,41 cm ja nyt se oli noussut 1,00 cm:ään, mutta puolestaan RMSE oli parantanut 3,31 cm:stä 2,82 cm:ään. Myös runkoluku (N) oli hieman tarkempi. Pohjanpinta-alan (G) ja keskitilavuuden (V) osalta tarkkuus oli heikentynyt aiempaan aineistoon verrattuna. BIAS oli 6,13 m²/ha ja 41,46 m³/ha. Suhteellinen BIAS kasvoi aiempaan verrattuna 7 % ja 9 %. Myös RMSE luvut kasvoivat. Pohjanpinta-alalla (G) se oli 8,98 m²/ha ja keskitilavuudella (V) 67,2 m³/ha. Suhteellinen RMSE nousi vastaavasti 5 % ja 4 %. Regressioanalyysissä ei havaittu merkittäviä eroja. Selityskertoimen R² arvot pysyivät 0,01 vaihtelun sisällä aiempaan aineistoon verrattuna. Taulukoissa 14, 15 ja 16 tarkkuudet vielä puulajeittain.

	G	V	D	H	N
BIAS	0,82	5,44	4,08	0,96	52,3
BIAS%	9	8	18	6	11
RMSE	3,58	32,25	6,77	1,64	245,6
RMSE%	38	46	30	11	51
R ²	0,79	0,76	0,63	0,92	0,89

Taulukko 14. Päivitetyn aineiston mäntyjen puustotunnusten tarkkuus.

	G	V	D	H	N
BIAS	4,06	28,4	-1,44	-1,74	301,3
BIAS%	29	27	-9	-14	32
RMSE	6,72	53,3	5,35	4,24	482,8
RMSE%	48	51	34	35	51
R ²	0,84	0,88	0,63	0,57	0,62

Taulukko 15. Päivitetyn aineiston kuusien puustotunnusten tarkkuus.

	G	V	D	H	N
BIAS	0,21	2,02	-2,03	-1,52	3,0
BIAS%	13	15	-22	-18	4
RMSE	1,14	9,33	7,25	6,39	86,6
RMSE%	69	67	78	75	106
R ²	0,92	0,93	0,48	0,36	0,57

Taulukko 16. Päivitetyn aineiston lehtipuiden puustotunnusten tarkkuus.

Männyn puustotunnuksista pohjanpinta-alan (G), keskitilavuuden (V) ja keskiläpimitan (D) BIAS ja RMSE olivat kasvaneet aiempaan verrattuna. Keskipituus (H) ja runkoluku (N) olivat puolestaan hiukan tarkentuneet. Kuusilla oli käynyt samalla tavalla, paitsi keskiläpimitan (D) tarkkuus oli parantunut. Sen BIAS oli enää -2,03 cm ja RMSE 5,35 cm. Lehtipuiden puustotunnusten tarkkuus oli pysynyt lähes samana.

5.6 Kalibroitimilla lisätyt puut

Lisäpuuaineiston normaalijakautuneisuus testattiin, jonka mukaan niille tehtiin T- tai U-testit (taulukko 17). Koko alueen runkoluvun (N) ja kuusen runkoluvun (N) osalta aineistot poikkesivat tilastollisesti merkitsevästi toisistaan. Kaikilla muilla puustotunnuksilla nollahypoteesi jäi voimaan.

koko alue	T-testi	U-testi	mänty	T-testi	U-testi	kuusi	T-testi	U-testi	lehti-puu	T-testi	U-testi
G		H ₀	G		H ₀	G		H ₀	G		H ₀
V		H ₀	V		H ₀	V		H ₀	V		H ₀
D	H ₀		D		H ₀	D	H ₀		D		H ₀
H	H ₀		H		H ₀	H	H ₀		H		H ₀
N		H ₁	N		H ₀	N		H ₁	N		H ₀

Taulukko 17. T- ja U-testien tulokset puustotunnuksittain sekä puulajeittain lisäpuuaineistosta.

Lisäämällä puita droneaineistoon saatiin parannettua metsikön inventointitulosta. Sen mukaan tutkimusalueen puuston kokonaistilavuus on 810 m³. Taulukosta 18 voi tarkastella tutkimusalueen puustotunnuksia. Koko alueen puustotunnusten tarkkuudet esitetään taulukossa 19.


Tutkimusalue	G, m ² /ha	V, m ³ /ha	D, cm	H, m	N, kpl/ha
Maasto	26,4	203,7	20,3	14,8	1 320
Drone 10.3.	22,4	183,3	20,6	15,5	978
Drone 13.4.	20,4	163,6	19,1	15,2	982
Lisäpuut	24,8	200,8	19,7	15,2	1 096

Taulukko 18. Puusto tutkimusalueella eri aineistojen mukaan.


	G	V	D	H	N
BIAS	2,08	7,91	0,45	-0,30	315,1
BIAS%	8	4	2	-2	20
RMSE	7,33	61,2	3,8	1,29	611,0
RMSE%	28	31	20	9	38
R ²	0,65	0,79	0,75	0,96	0,60

Taulukko 19. Lisäpuuaineiston puustotunnusten tarkkuus tutkimusalueella.


Kaikkien puustotunnusten tarkkuus parani tai pysyi lähes samana. Eniten tarkkuus parani pohjanpinta-alan (G), keskitilavuuden (V) ja runkoluvun (N) osalta. Keskitilavuuden BIAS oli enää 7,91 m³/ha ja RMSE 61,2 m³/ha. BIAS on pienentynyt kolmanneksen verrattuna droneaineistoon 10.3. ja RMSE on pysynyt samalla tasolla. Selityskertoimet R² ovat hieman laskeneet pohjanpinta-alan (G), keskitilavuuden (V) ja keskiläpimitan (D) osalta. Näiden tunnusten sirontakuviot esitetään kuvioissa 22, 23 ja 24.



Kuvio 22. Sirontakuviio ja regressiosuora tutkimusalueen pohjanpinta-aloista lisäpuuaineistossa.



Kuvio 23. Sirontakuviio ja regressiosuora tutkimusalueen keskilavuuksista lisäpuuaineistossa.



Kuvio 24. Sirontakuviio ja regressiosuora tutkimusalueen keskiläpimitoista lisäpuuaineistossa.

Taulukoista 20, 21 ja 22 voi tarkastella puustotunnusten tarkkuutta puulajeittain. Mäntyjen ja lehtipuiden osalta havaittiin tulosten heikentymistä. Kuusen osalta tarkkuus parani kaikissa puustotunnuksissa.

	G	V	D	H	N
BIAS	-0,97	-8,31	3,87	0,97	0,15
BIAS%	-10	-12	17	6	0
RMSE	5,11	47,74	6,75	1,64	241,4
RMSE%	54	68	30	11	50
R ²	0,73	0,71	0,60	0,92	0,85

Taulukko 20. Lisäpuuaineiston mäntyjen puustotunnusten tarkkuus.

	G	V	D	H	N
BIAS	2,38	14,21	-1,35	-1,73	247,0
BIAS%	17	14	-9	14	26
RMSE	5,07	41,88	5,35	4,24	437,1
RMSE%	36	40	34	35	46
R ²	0,84	0,86	0,62	0,57	0,65

Taulukko 21. Lisäpuuaineiston kuusien puustotunnusten tarkkuus.

	G	V	D	H	N
BIAS	-0,36	-3,59	-2,56	-1,52	1,4
BIAS%	-22	-26	-28	-18	2
RMSE	3,98	38,4	8,11	6,39	86,7
RMSE%	242	275	87	75	106
R ²	0,73	0,77	0,45	0,36	0,56

Taulukko 22. Lisäpuuaineiston lehtipuiden puustotunnusten tarkkuus.

Männyllä runkoluvun (N) määrittämisen tarkkuus parani ja suhteellinen BIAS oli 0 %. Jostain syystä pohjanpinta-alan (G), keskitilavuuden (V) ja keskiläpimitan (D) osalta tulokset kuitenkin heikkenivät merkittävästi, vaikka runkoluvun tarkkuuden paranemisen olisi voinut luulla kasvattavan myös muiden puustotunnusten tarkkuutta. Aliskasvospuista suurin osa oli kuusia ja luultavasti siitä syystä kuusen kaikki puustotunnukset tarkentuivat. Keskiläpimitan suhteellinen BIAS oli -9 % ja suhteellinen RMSE 34 %. Aliskasvospuiden lisääminen siis puolitti keskiläpimitan yliarvion. Lehtipuiden keskipituus (H) ja runkoluku (N) pysyvät lähes samoina. Mutta muiden puustotunnusten osalta tarkkuus heikentyi 10.3. droneaineistoon verrattuna.

6 Pohdinta

6.1 Tulosten tarkastelu

Tutkimusalueen puista 68 % havaittiin dronekuvista. Havaitsematta jäivät pienimpiin läpimittaluokkiin kuuluvat aliskasvospuut, joten sillä ei ollut suurta vaikutusta koealojen puustotunnuksiin, runkolukua lukuun ottamatta. Puustotunnusten harha oli pieni, mikä osoittaa, että tunnuksset ovat harhattomia. Tarkkuutta sen sijaan kuvaa RMSE, joka oli suurehko. Esimerkiksi keskitilavuuden suhteellinen harha oli 12 % ja suhteellinen RMSE oli 30 %. Tästä voidaan päätellä, että puustotunnuksissa löytyy virheitä, mutta ne kumoavat toisensa. Selityskertoimen arvot ylittivät pohjanpinta-alan, keskiläpimitan, keskipituuden ja keskitilavuuden osalta asetetun 0,7 rajan. Näissä tapauksissa mallia voidaan pitää toimivana metsäninventointitarkoitukseen.

Jos tutkimusaluetta tarkastellaan puulajeittain, männyn havaittiin parhaiten, 95 %, ja myös sen puustotunnukset saivat tarkimmat arvot. Keskitilavuuden osalta suhteellinen harha oli vain -3 %, mutta suhteellinen RMSE 54 %. Tämä voi johtua siitä, että puulajin määrittäminen ei ole mennyt oikein, joka on aiheuttanut suuria

heittoja joillekin koaloille. Toisaalta pienestä harhasta päätellen virheitä on tapahtunut molempiin suuntiin, joten inventoinnin lopputuloksen kannalta sillä ei ole suurta merkitystä. Keskiläpimitan osalta selityskerroin jäi alle 0,7:n, mutta muiden puustotunnusten osalta drone ja maastoaineistot vastaavat hyvin toisiinsa.

Kuusissa aliskasvokset aiheuttivat sen, että puista havaittiin vain 55 %. Keskitilavuuden ja pohjanpinta-alan regressiomallit selittivät silti hyvin aineistoja, vaikka suhteellinen RMSE oli 40 %:n luokkaa. Keskiläpimitan, keskipituuden ja etenkin runkoluvun osalta tulosta ei voida pitää luotettavana. Drone antaa yliarvion keskiläpimitasta 17 % ja yliarvion keskipituudesta 15 %, koska pienet aliskasvokset eivät ole laskemassa näitä arvoja. Runkolukusarjoista tehty huomio suurien kuusten luokittelusta pienempään läpimittaluokkaan ei näykkään keskiläpimitassa oletettuna aliarviona. Mutta se johtunee tunnistamattomien aliskasvopuiden merkittävämmästä määrästä. Keskitilavuus puolestaan aliarvioitiin dronekuvien pohjalta noin 19 m³/ha pienemmäksi. Voisiko tämä johtua aiemmin tehdystä huomiosta? Voisiko kuusien runkomalleja muuttamalla parantaa keskitilavuuden määrittämisen tarkkuutta? Metsäinventoinnin näkökulmasta keskitilavuutta voidaan pitää tärkeimpänä puustotunnuksena ja sen tarkkuuden parantamisella saadaan lisähyötyä inventointitulokseen.

Lehtipuita oli tutkimusalueella vähän ja ne kasvoivat lähinnä sekapuuna. Tästä syystä niiden otantaa ei voida pitää riittävän suurena ja näihin tuloksiin on suhtauduttava tapauskohtaisina. Lehtipuista tunnistettiin 70 % ja niiden puustotunnusten määrittäminen onnistui heikoiten. Suhteellinen RMSE oli kaikissa yli 70 %, eli virheet olivat merkittäviä. Pienestä harhasta voidaan päätellä, että osa virheistä onnistuu kumoamaan toisensa ja siksi eivät tee suurta muutosta koko alueen inventointitulokseen. Selityskertoimet ovat keskiläpimitan, keskipituuden ja runkoluvun osalta heikkoja ja alittavat 0,7 tason.

Päivitetystä droneaineistossa (13.4.) keskipituuden ja runkoluvun tarkkuus oli parantunut. Metsien inventoinnin näkökulmasta tärkeimpiä tunnuksia ovat pohjanpinta-ala ja keskitilavuus, joiden osalta muutos oli tapahtunut huonompaan suuntaan. Puulajeista kuusen keskiläpimita ja keskitilavuus parantuivat

aiempaan aineistoon verrattuna. Havainnot tulkinnan heikentymisestä johtuvat siitä, että päivitettyä versiota muokattiin skaalautuvammaksi. Se ei ole yhtä riippuvainen opetusaineistosta ja antaa tasaisempi tuloksia koealaverkon ulkopuolella. Aiempi versio vastaa puolestaan paremmin maastokoealoja, ja siksi päivitetyn aineiston tulokset ilmenevät sitä heikompina.

Lisäpuuaineistossa kaikkien puustotunnusten tarkkuus parani. Voidaan havaita, että vähiten parannusta tapahtui keskipituuden (H) osalta. Sen osalta on saavutettu tarkkuus, johon on mahdollista päästä ja menetelmän kehittäminen ei luultavasti parantaisi sen tarkkuutta enää merkittävästi. Sen sijaan muita puustotunnuksia on mahdollista kehittää vielä tarkemmiksi. Harhat (BIAS) olivat hyvin pieniä, mutta suhteellisen RMSE osalta tunnusluvut pyörivät 20 % yläpuolella. Runkoluku (N) on aina haastavin, kun metsiä inventoidaan ylhäältä päin. Voisiko sen tarkkuutta parantaa esimerkiksi tiheäpulssisen laserkeilausaineiston avulla? Luultavasti myös muut tunnusluvut tarkentuisivat sen myötä.

Kun tämän opinnäytetyön tuloksia vertaillaan muihin vastaaviin tutkimuksiin, voidaan löytää yhteisiä piirteitä tuloksissa. Ravaskan ja Solehmaisen (2021) opinnäytetyössä käsiteltiin myös dronekuvista fotogrammetrian menetelmillä tuotettujen puustotunnusten luotettavuutta. Heidän työssään oli toteutettu maastomittaukset eri tavalla ja luultavasti myös dronelaitteistossa ja dronekuvien tulkintamenetelmissä on eroja tähän työhön verrattuna. Myös aineistojen analyysissä oli käytetty eri tilastollisiamenetelmiä, joten tuloksia ei voida suoraan verrata keskenään. He tarkastelivat, osuivatko droneinventoinnin tulokset 95 % luottamusvälille maastomittauksista. Lopputulos oli, että droneinventointia ei voitu pitää riittävän luotettavana menetelmänä, joka poikkeaa tämän tutkimuksen lopputuloksesta. Saman suuntaisia havaintoja tämän opinnäytetyön kanssa oli se, että parhaimmat tulokset saatiin männiköistä.

Korhosen ja Kuivalaisen (2019) opinnäytetyö käsitteli myös fotogrammetrista metsänmittausmenetelmää dronekuvien pohjalta. Erona tähän tutkimukseen on se, että siinä käsiteltiin puita, joille löydettiin vastinparit eli piiloon jääneitä puita ei otettu huomioon. Tuloksia verrattiin Maanmittauslaitoksen laserkeilausaineistoon. He saivat lopputulokseksi, että menetelmää voidaan pitää luotettavana.

Puulajien tunnistamisen tarkkuudet olivat männyllä 93 %, kuusella 84 % ja koivulla 92 %. Näitä ei voida suoraan verrata tämän opinnäytetyön tuloksiin, koska tässä työssä aliskasvospuut ovat mukana referenssiaineistossa, joka heikentää lajin tunnistustarkkuutta. Yhteisiä havaintoja tämän tutkimuksen kanssa ovat pituuden määrittämisen paras tarkkuus sekä läpimitan aliarvio järeissä puuyksilöissä. Korhosen ja Kuivalaisen (2019) tutkimuksessa pituuden keskiarvojen erotus oli 0,17 m. Se on lähellä tässä opinnäytetyössä laskettua harhaa, joka oli -0,44 m. Tasaikäisrakenteisen metsän parempi inventointitulos ja piiloon jäävät aliskasvospuut olivat myös yhteisiä todettuja piirteitä.

Pulitin ym. (2015) tutkimuksen kanssa lopputulokset puustotunnusten tarkkuuksissa olivat samaa luokkaa. Tämä voidaan todeta, kun vertaillaan taulukoita 2 ja 5. Suhteelliset RMSE:t olivat keskipituuden ja runkoluvun osalta samalla tasolla, mutta pohjanpinta-alassa ja keskitilavuudessa Pulitin ym. (2015) tulokset olivat tarkemmat. Suhteellinen harha oli keskipituuden ja pohjanpinta-alan ja osalta lähellä toisiaan, mutta keskitilavuudessa ja runkoluvussa tässä opinnäytetyössä saatiin tarkemmat arvot. Selityskertoimen R^2 oli Pulitin ym. (2015) saatu ristiinvalidoimalla aineisto (cross validating). Tässä opinnäytetyössä se on puolestaan saatu regressioanalyysistä. Vaikka menetelmät ovat erilaiset, niin selityskertoimia voidaan, ainakin suuntaa antavasti, vertailla keskenään, koska virheenlaskutapa on sama. Tutkimuksien välillä selityskertoimet olivat samaa suuruusluokkaa ja liikkuivat 0,6 yläpuolella.

Tämän opinnäytetyön tulokset pärjäävät tarkkuudessaan hyvin myös laserkeilauspohjaisille inventointituloksille. Uutteran ym. (2006) tutkimuksen sekä tämän opinnäytetyön puustotunnusten tarkkuudet esitellään taulukossa 23. Droneaineisto (10.3.) ei aivan yltänyt laserkeilausta vastaavaan tarkkuuteen, mutta erot olivat yllättävän pieniä. Keskitilavuus yliarvioitiin Uutteran ym. (2006) tutkimuksessa 14 m^3 . Tässä tutkimuksessa keskitilavuus puolestaan aliarvioitiin 24 m^3 . Keskipituuden ja runkoluvun osalta päästiin lähes samoihin tarkkuuksiin. Lisäpuuaineistossa pystyttiin päihittämään Uutteran ym. (2006) tulokset. Keskitilavuuden ja keskiläpimitan osalta harhat (BIAS) olivat pienemmät, mutta suhteelliset RMSE:t olivat suuremmat. Pohjanpinta-alan, keskipituuden ja runkoluvun tarkkuudet olivat samalla tasolla.

LASER (Utterä, ym.)	G	V	D	H	N
BIAS	-2,6	-14	-0,9	0,2	315
RMSE%	23	19	13	9	41
DRONE 10.3	G	V	D	H	N
BIAS	4,23	23,5	-0,41	-0,44	427
RMSE%	29	30	17	10	42
LISÄPUU	G	V	D	H	N
BIAS	2,08	7,91	0,45	-0,30	315
RMSE%	28	31	20	9	38

Taulukko 23. Laserkeilatun (Utterä, ym. 2006), dronekuvista tulkitun aineiston (10.3) ja lisäpuuaineiston tarkkuudet.

Kankaan ym. (2019) metsävaratiedon hyötyanalyysissä esiteltiin laserkeilausaineistoon pohjautuvien puustotunnusten tarkkuudet puulajeittain. Ne esitellään taulukossa 24. Puustotunnusten suhteelliset harhat ovat samaa tasoa tai osittain parempia. RMSE:t ovat huomattavasti suurempia keskitilavuuden, keskilämpötilan ja runkoluvun osalta. Kuusen keskitilavuuden RMSE on 107 %, joka on yli kaksinkertainen tässä tutkimuksessa saatuun verrattuna. Tämä osoittaa sen, että droneinventointi ylittää parempaan tarkkuuteen puulajeittain tarkasteltuna. Kangas ym. (2019) totesivat, että puulajin tunnistuksessa on niin paljon virheitä, että se on taloudellisesti kannattavaa käydä tarkastamassa maastossa. Droneinventoinnilla voidaan siis välttää tämä maastokäynti.

MÄNTY	G	V	D	H	N
BIAS%	-4	-3	-2	-2	-2
RMSE%	78	86	23	12	84
KUUSI	G	V	D	H	N
BIAS%	2	1	-14	-15	6
RMSE%	96	107	42	38	96
LEHTIPUU	G	V	D	H	N
BIAS%	7	6	-20	-12	11
RMSE%	150	158	61	39	166

Taulukko 24. Puustotunnusten tarkkuus puulajeittain (Kangas, ym. 2019).

AFRY on tutkinut menetelmän tarkkuutta Suomessa ja yksi tutkimusalueista oli Keski-Suomessa Äänekoskella. Vuonna 2021 toteutettiin maasto- ja droneinventointi. Dronessa oli RGB-kamera 3,5 cm:n resoluutiolla ja multispektrikamera 10 cm:n resoluutiolla. (Sarkeala 2021) Tulokset esitetään taulukossa 25.

	G	V	D	H
BIAS%	0,1	1,7	3,6	-1,8
RMSE%	14	13	8	3

Taulukko 25. AFRY:n droneinventoinnin tarkkuus Keski-Suomen tutkimusalueella. (Sarkeala 2021)

Tulokset olivat huomattavasti parempia, kuin tässä tutkimuksessa saatiin. Mistä johtuu tutkimuksien välinen ero? Dronejen laitteistosta ei löydy havaintoa selittävää eroa, sillä tämän tutkimuksen kameroissa oli korkeampi resoluutio. Tutkimusalueet sijaitsevat samalla kasvillisuusvyöhykkeellä, mutta eri valtioissa. Ruotsin ja Suomen välillä on eroja metsänhoidossa, joka voi aiheuttaa eroavaisuuksia myös metsikön rakenteeseen. Esimerkiksi taimikonhoidon rästien ja myöhäisempien harvennusten takia metsät kasvavat tiheämpinä ja siellä on enemmän aliskasvospuita. Ruotsissa metsiä kasvatetaan tiheämpänä, eikä niitä harvenneta yhtä usein kuin Suomessa (Blom 2018; Häkkinen 2018). Tästä voisi johtua haasteet dronekuviin pohjautuvassa inventoinnissa. Toisaalta taimikonhoitojen määrän osalta Ruotsi on mennyt Suomesta ohi (Metsälehti 2022), joka voi muuttaa metsien rakennetta tulevaisuudessa droneinventoinnille suotuisampaan suuntaan.

Vertailu muihin tutkimuksiin tukee tässä saatuja tuloksia, sillä saman suuntaisia havaintoja on tehty jo aikaisemmin. Droneinventoinnin etuja on sen yksityiskohdaisuus, puulajin tunnistuksen tarkkuus, tiedon tuoreus sekä toteutuksen edullisuus pienillä alueilla. Sen kilpailukykyisyys laserkeilaukseen pohjautuvan inventoinnin kanssa on merkittävää. Se tarkoittaa sitä, että dronesta on tulossa kilpailukykyinen vaihtoehto alueille, joita ei ole laserkeilattu pitkään aikaan. Droneinventoinnin avulla voidaan nostaa alueen inventointitiedon tasoa.

6.2 Luotettavuus

Otoskoko eli koealojen määrä oli 49 ja sitä voidaan pitää riittävän kattavana antamaan kokonaiskuvan perusjoukosta. Maastomittaukset tehtiin uudella puukartta-mittaustekniikalla ja käytössä olivat tarkat mittalaitteet. Mittauksien tekeminen 2 hengen ryhmissä paransi myös mittaustarkkuutta. Dronelennot toteutettiin laatuvaatimuksia noudattaen ja kaikki aineistot prosessoitiin moderneilla algoritmeilla. Kun aineiston kerääminen on toteutettu teknologian, avulla, tekijän rooli siitä on hyvin etäinen (Vilka 2021, 200). Näiden asioiden pohjalta tutkimuksen lähtökohtia voidaan pitää luotettavina.

Tutkimuksessa käytettiin olettamuksia, esimerkiksi lukupuiden pituuden mallintamisessa. Silloin luotetaan runkomallien ennustamiin arvoihin, mikä voi joissain määrin aiheuttaa epätarkkuuksia, koska puut ovat yksilöitä. Täytyy pohtia sitä, että onko epävarmemmalla tiedolla suurta merkitystä lopputuloksen kannalta. Olisiko merkittävää lisähyötyä saatu, vaikka kaikista puista olisi mitattu pituus? Maastomittauksissa ei ole mahdollista päästä aivan absoluuttiseen tarkkuuteen, joten riittävän tason hakeminen, on tutkimuksen pätevyyden kannalta olennaista.

Dronekuvista puuston pituuden mittaus on todella tarkkaa, joten on todennäköistä, että se on mallinnettuja pituuksia tarkempaa. Eli keskipituuden tarkkuus ei kuvaa välttämättä droneinventoinnin tarkkuutta vaan inventointimenetelmien välistä eroa. Puun pituus on tärkeä parametri muiden puustotunnusten laskennassa, joten myös muut tunnukset sisältävät tätä pituustarkastelun epävarmuutta.

Tässä opinnäytetyössä on saavutettu tavoiteltu tarkkuus ja pystytty selvittämään taso, jolle droneinventoinnilla on päästy. Puuyksilöiden tunnistamisen ja puustotunnusten tulkinnan onnistuminen saatiin selvitettyä ja tämä tutkimus antaa kuvan menetelmän toimivuudesta, sekä sen kehityskohteista.

6.3 Hyödynnettävyys ja jatkotutkimustarpeet

Fotogrammetrian ja dronekuvien avulla tehtyyn metsäinventointiin liittyen ei ole vielä tehty riittävästi tutkimusta. Dronet ottavat jatkuvasti suurempaa roolia metsäalalla, ja niiden mahdollisuudet eri tehtävissä on hyvä selvittää. Jatkotutkimusta tarvitaan tämän opinnäytetyön olosuhteita vastaavissa oloissa, jotta tuloksille saadaan tukea. Tässä opinnäytetyössä havaittiin, että lehtipuiden puus- totunnusten määrittäminen oli havupuita heikompaa. Siksi lehtipuumetsiin kohdistuvalle tutkimukselle on tarvetta.

Myös lehdettömän ajan vaikutus inventointitulokseen olisi mielenkiintoista saada selville. Kuinka paljon se parantaisi koivikoiden aliskasvoskuusien havainnointia? Pelkästään kuolleisiin puihin keskittyvälle tutkimukselle olisi myös tarvetta. Muilta kasvillisuusvyöhykkeiltä ja eri-ikäisrakenteisista metsistä täytyy tehdä lisätutkimuksia. Jatkotutkimuksissa voi selvittää eri drone- ja kameralaitteistojen, prosessointiohjelmistojen sekä latvus-läpimitta-mallinnusmenetelmien vaikutuksia inventointitulokseen.

Lähteet

- AFRY. 2022. Tietoa meistä. <https://afry.com/fi-fi/tietoa-meista>. 7.12.2022.
- Agisoft LLC. 2018. Agisoft PhotoScan User Manual: Professional Edition, Version 1.4.
- Antinluoma, J. & Rahkola, S. 2022. Puukarttojen mittaus. Suomen Metsäkeskus.
- Auvinen, P., Pukkala, T. & Vesa, L. 2002. Metsän kartoitus. Verkkopainos. Joensuu: Joensuun yliopiston metsätieteellinen tiedekunta, Pohjois-Karjalan ammattikorkeakoulu ja Sordino Information Systems Oy.
- Blom, J. (6.8.2018). Metsäpalojen tuntija varoo lietsomasta paniikkia. Hämeen-sanomat. <https://www.hameensanomat.fi/paikalliset/5211971>.
- Droneinfo. 2022. Drone ja sen toiminnot – miehittämättömien ilma-alusten yleistuntemus. <https://www.droneinfo.fi/fi/koulutusmateriaali/drone-ja-sen-toiminnot-miehittamattomien-ilma-alusjarjestelmien-yleistuntemus?toggle=Drone-j%C3%A4rjestelm%C3%A4n%20toiminnot%2C%20jotka%20tulee%20hallita>. 16.1.2023.
- Geodetic Services. 2017. Basics of Photogrammetry. https://www.geodetic.com/wp-content/uploads/2019/01/Basics_of_Photogrammetry_2017.pdf.
- Grybas, H. & Congalton, R. G. 2021. A Comparison of Multi-Temporal RGB and Multispectral UAS Imagery for Tree Species Classification in Heterogeneous New Hampshire Forests. *Remote Sens.* 2021, 13, 2631. <https://doi.org/10.3390/rs13132631>.
- Guillermo, C., Filiatrault, M., McDermid, G. J. & Gartrell, M. 2020. Estimating Individual Conifer Seedling Height Using Drone-Based Image Point Clouds. *Forests* 2020, 11, 924; doi:10.3390/f11090924.
- Hardenbol, A.A., Kuzmin A., Korhonen L., Korpelainen P., Kumpula T., Maltamo M. & Kouki, J. 2021. Detection of aspen in conifer-dominated boreal forests with seasonal multispectral drone image point clouds. *Silva Fennica* vol. 55 no. 4 article id 10515.
- Helve, O., Komulainen, J., Pyörälä, E., Merenmies, J. & Holopainen, J. 2014. Hyvän artikkelin anatomia – 3. osa: tilastotiede. *Lääketieteellinen aikakauskirja Duodecim*. 130(22):2356-7.
- Holopainen, M., Hyyppä, J. & Vastaranta, M. 2013. Laserkeilaus metsävarojen hallinnassa. Helsingin yliopiston metsätieteiden laitoksen julkaisuja, Nro 5, Helsinki.
- Hyvönen, P. 2002. Kuvioittaisten puustotunnusten ja toimenpide-ehdotusten estimointi k-lähimmän naapurin menetelmällä Landsat TM -satelliittikuvan, vanhan inventointitiedon ja kuviotason tukiaineiston avulla. *Metsätieteen aikakauskirja* 3/2002: 363–379.
- Häkkilä, T. (19.7.2018). Miksi Ruotsin metsät roihuavat Suomea pahemmin? Asiantuntija selittää, miksi Ruotsissa metsäpalo lähtee nopeammin käsistä. *Ilta-Sanomat*. <https://www.is.fi/kotimaa/art-2000005762825.html>.
- Imangholiloo, M., Saarinen, N., Markelin, L., Rosnell, T., Nasi, R., Hakala, T., Honkavaara, E., Holopainen, M., Hyyppä, J. & Vastaranta, M. 2019.

- Characterizing Seedling Stands Using Leaf-Off and Leaf-On Photogrammetric Point Clouds and Hyperspectral Imagery Acquired from Unmanned Aerial Vehicle. *Forests*, vol. 10, nro. 5, 415. <https://doi.org/10.3390/f10050415>.
- Kangas, A., Haara, A., Holopainen, M., Luoma, V., Packalen, P., Packalen, T., Ruotsalainen, R. & Saarinen, N. 2019. Kaukokartoitukseen perustuvan metsävaratiedon hyötyanalyysi: MetKu-hankkeen loppuraportti. Luonnonvara- ja biotalouden tutkimus 6/2019. Luonnonvarakeskus. Helsinki. 32 s.
- Karjalainen, T., Packalen, P., Rätty, J. & Maltamo, M. 2019. Predicting factual sawlog volumes in Scots pine dominated forests using airborne laser scanning data. *Silva Fennica* vol. 53 nro. 4 article id 10183.
- Karte, S. 2022. Toimihenkilö. Metsälinkki Oy. Koealojen valokuvat.
- Korhonen, L. 2022. Toimitusjohtaja. Metsälinkki Oy. Kirjallinen tiedoksianto. 10.12.2022.
- Korhonen, L. & Kuivalainen, K. 2019. Fotogrammetrinen metsänmittausmenetelmä. Karelian ammattikorkeakoulu. Metsätalouden koulutusohjelma. Opinnäytetyö. <https://urn.fi/URN:NBN:fi:amk-2019091918925>. 7.4.2023.
- Korpela, I., Ørka, H.O., Maltamo, M., Tokola, T. & Hyypä, J. 2010. Tree species classification using airborne LiDAR – effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fennica* 44(2): 319–339.
- Lantmäteriet. 2023. Laser data Download. <https://www.lantmateriet.se/en/geodata/geodata-products/product-list/laser-data-download-nh/>. 15.4.2023.
- Lisein, J., Pierrot-Deseilligny, M., Bonnet, S. & Lejeune, P. 2013. A Photogrammetric Workflow for the Creation of a Forest Canopy Height Model from Small Unmanned Aerial System Imagery. *Forests* 2013, 4, 922–944; doi:10.3390/f4040922
- Luke. 2022. Pääpuulajien tilavuusmallit on päivitetty. <https://www.luke.fi/fi/uutiset/paapuulajien-tilavuusmallit-on-paivitetty>. 23.1.2023.
- Luke. 2015. Valtakunnan metsien inventointi. <http://www.metla.fi/ohjelma/vmi/vmi-moni.htm>. 30.11.2022.
- Lyytikäinen-Saarenmaa, P., Kantola, T., Blomqvist, M. & Kosunen, M. 2015. Hyönteistuhoriskien hallinta uusilla teknologioilla. *Metsätieteen aikakauskirja* 1/2015: 36–41.
- Maanmittauslaitos. 2022. Korkeusmallit. <https://www.maanmittauslaitos.fi/tutkimus/teematietoa/korkeusmallit>. 1.12.2022.
- Maanmittauslaitos. 2022. Maanmittauslaitoksen ilmakeku. <https://www.maanmittauslaitos.fi/kartat-ja-paikkatieto/asiantuntevalle-kayttajalle/tuotekuvaukset/ilmakeku>. 16.11.2022.
- Maltamo, M., Packalén, P., Uuttera, J., Ärölä, E. & Heikkilä, J. 2008. Laserkeilaustulkinnan hyödyntäminen metsäsuunnittelun tietolähteenä. *Metsätieteen aikakauskirja* 4/2008: 304–309.
- Metsäkeskus. 2022. Metsävaratieto. <https://www.metsakeskus.fi/fi/avoin-metsa-ja-luontotieto/tietojen-yllapito/tiedonkeruu>. 16.11.2022.
- Nezami, S., Khoramshahi, E., Nevalainen, O., Pölönen, I. & Honkavaara, E. 2020. Tree Species Classification of Drone Hyperspectral and RGB Imagery with Deep Learning Convolutional Neural Networks. *Remote Sens.* 2020, 12, 1070; doi:10.3390/rs12071070.

- Nordic Drones Oy. 2022. Tuotetiedot. <https://nordicdrones.fi/tuotteet/tuotetiedot/>. 28.12.2022.
- Paananen, R. 2018. Drone -kuvausten käyttökelpoisuudesta Metsäkeskuksen toiminnassa. Maaseutu 2.0 loppuseminaari 24.1.2018. Suomen Metsäkeskus.
- Peuhkurinen, J., Maltamo, M. & Malinen, J. 2008. Estimating species-specific diameter distributions and saw log recoveries of boreal forests from airborne laser scanning data and aerial photographs: a distribution-based approach. *Silva Fennica* 42(4): 625–641.
- Pix4d. 2019. Ground Control Points: why are they important. <https://www.pix4d.com/blog/why-ground-control-points-important>. 17.1.2023.
- Pix4d. 2022. Parrot Sequoia +. <https://www.pix4d.com/product/sequoia>. 31.12.2022.
- Pix4d. 2022. RTK vs PPK drones vs GCPs: which provides better results. <https://www.pix4d.com/blog/rtk-ppk-drones-gcp-comparison>. 17.1.2023.
- Puliti, S., Ørka, H.O., Gobakken, T. & Næsset, E. 2015. Inventory of Small Forest Areas Using an Unmanned Aerial System. *Remote Sens.* 2015, 7, 9632–9654; doi:10.3390/rs70809632.
- Ravaska, M. & Solehmainen, A. 2021. Fotogrammetrialla ja yksinpuintulkinnalla tuotetun puustotiedon luotettavuus. Karelialan ammattikorkeakoulu. Metsätalouden koulutusohjelma. Opinnäytetyö. <https://urn.fi/URN:NBN:fi:amk-202104245629>. 7.4.2023.
- Saarinen, N., Vastaranta, M., Nasi, R., Rosnell, T., Hakala, T., Honkavaara, E., Wulder, M. A., Luoma, V., Tommaselli, A. M. G., Imai, N. N., Ribeiro, E. A. W., Guimaraes, R. B., Holopainen, M. & Hyypä, J. 2018. Assessing Biodiversity in Boreal Forests with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. *Remote Sensing*. vol. 10. no. 2. 338. <https://doi.org/10.3390/rs10020338>.
- Sarkeala, J. 2021. Treemaps droneinventory accuracy. AFRY.
- Senop Oy. 2022. Hyperspectral imaging. <https://senop.fi/optics-imaging/hyperspectral-imaging/>. 31.12.2022.
- Seppälä, T. 2021. Tekoälyn hyödyntäminen taimikonhoidon työvaikeuden määrittämisessä. Karelialan ammattikorkeakoulu. Metsätalouden koulutusohjelma. Opinnäytetyö. <https://urn.fi/URN:NBN:fi:amk-2021061015560>. 10.12.2022.
- Sirro, L., Häme, T., Rauste, Y., Pitkänen, T., Kangas, A., Törmä, M., Häme, L., Huotari, R. & Norppa, J. 2019. Metsävaratiedon ajantasaistus – satelliittikuviin perustuva muutostulkinta. MMM. Loppuraportti.
- Suomen Metsäkeskus. 2022. Metsävaratiedon laatuseloste.
- Suvanto, A., Maltamo, M., Packalén, P. & Kangas, J. 2005. Kuviokohtaisten puustotunnusten ennustaminen laserkeilauksella. *Metsätieteen aikakauskirja* 4/2005: 413–428.
- Taanila, A. 2020. Lineaariset regressiomallit. <https://taanila.fi/regressio.pdf>.
- Taanila, A. 2022. Lineaarinen regressiomalli. Akin menetelmäblogi. <https://tilastoapu.wordpress.com/lineaarinen/>. 3.4.2023
- Talkkari, A & Lehmonen, H. 2021. Metsävaratieto - hankinta ja hyödyntäminen. Helsinki: Tapio Palvelut Oy.

- Tarp-Johansen, M. J. 2002. Stem Diameter Estimation from Aerial Photographs. Department of Mathematics and Physics, Royal Veterinary and Agricultural University. Nro 17: 269–276. Tanska.
- Taylor, J. 1997. An introduction to Error Analysis. University Science Books. California.
- Tähtinen, J., Laakkonen, E. & Broberg, M. 2020. Tilastollisen aineiston käsittelyn ja tulkinnan perusteita. Turku: Painoslama Oy.
- Törmä, M. 2004. Fotogrammetrian ja kaukokartoituksen sanasto. Helsingin teknillinen korkeakoulu. <https://foto.aalto.fi/sanasto.html>. 24.4.2023.
- Utterä, J., Anttila, P., Suvanto, A. & Maltamo, M. 2006. Yksityismetsien metsävaratiedon keruuseen soveltuvilla kaukokartoitusmenetelmillä estimoitujen puustotunnusten luotettavuus. Metsätieteen aikakauskirja 4/2006: 507–519.
- Vilka, H. 2021. Näin onnistut opinnäytetyössä-ratkaisut tutkimuksen umpikujiin. Jyväskylä: PS-kustannus.
- VTT. 2023. Kasvitaudit löytyvät uudella teknologialla aiemmin, tarkemmin ja nopeammin. <https://www.vttresearch.com/fi/uutiset-ja-tarinat/kasvitaudit-loytyvat-uudella-teknologialla-aiemmin-tarkemmin-ja-nopeammin>. 24.4.2023

