

KARELIA-AMMATTIKORKEAKOULU
Metsätalouden koulutus

Pulkkinen Saana

KIRJANPAINAJATUHOJEN KARTOITUS
MULTISPEKTRIKAMERALLA

Opinnäytetyö
Tammikuu 2020



OPINNÄYTETYÖ
Tammikuu 2020
Metsätalouden koulutus

Karjalankatu 3
80200 JOENSUU
+358 13 260 600 (vaihde)

Tekijä
Saana Pulkkinen

Nimeke
Kirjanpainajatuhojen kartoitus multispektrikameralla

Toimeksiantaja
Stora Enso

Tiivistelmä

Ilmastonmuutoksen myötä tuuli- ja hyönteistuhot lisääntyvät Suomen metsissä. Erityisesti kuusia pystyyn kuivattava kirjanpainaja on hyötynyt lämpimistä ja kuivista kesistä. Kirjanpainajakannan runsastumisen myötä metsien terveyden kartoitus on tulevaisuudessa tärkeää, jotta metsänomistajien taloudellisia menetyksiä voidaan minimoida. Tässä työssä tutkittiin Stora Enso kehittämää mallia ja mallin tulkinnan esittämiseen käytettävää ohjelmaa metsän terveyden kartoittamiseen. Kartoitus tapahtui droonin avulla, johon oli kiinnitetty multispektrikamera, ja lennolta otetut kuvat ladattiin yhtiön drooni-palveluun.

Tutkimuksen kohteena oli kaksi kuusivaltaista metsää Lappeenrannassa, joissa oli aiempina vuosina havaittu kirjanpainajan tappamia kuusia. Kuvaukset ja mittaukset suoritettiin kesällä 2019. Työssä vertailtiin maastossa tehtyjä havaintoja ohjelman terveyslukittelun antamiin tuloksiin ja opetettiin referenssiaineistolla lisää ohjelman mallia. Opetuksen jälkeen maastohavaintoja verrattiin päivitetyn terveyslukittelun tuloksiin. Puiden terveys luokiteltiin asteikolla terve-sairas-kuollut.

Terveyslukittelumallin opetuksen myötä kuusien terveyden luokittelu parani 71 %:sta 86 %:iin. Paras tulos saatiin kuolleiden kuusien tunnistamisen osalta, missä malli 2018 luokitteli 96 % puista oikein ja malli 2019 100 % oikein. Tutkimuksessa havaittiin kehitystarpeita vielä puiden havainnoinnin parantamisessa sekä sairaiden puiden luokittelun täsmällisyydessä. Tulosten perusteella terveyslukittelussa on havaittavissa varovaisuutta, jolloin sairas puu saattaa luokitella väärin terveeksi. Tutkimuksen perusteella Stora Enson terveyslukitteluohjelmalla voidaan kuitenkin arvioida kuusimetsän terveyttä.

Kieli
suomi

Sivuja 48

Asiasanat

Kirjanpainaja, kaukokartoitus, miehittämättömät ilma-alukset, droonit



THESIS
January 2020
Degree Programme In Forestry

Karjalankatu 3
80200 JOENSUU
FINLAND
+ 358 13 260 600 (switchboard)

Author
Saana Pulkkinen

Title
Mapping of Bark Beetle Damages by Using Multispectral Camera

Commissioned by
Stora Enso

Abstract

With climate change, wind and insect damages will increase in Finnish forests. In particularly European spruce bark beetle has benefited from warm, dry summers. With increasing European spruce bark beetle population, forest health inventory will be important in the future to minimize the economic risks for forest owners. The objective of this study was to investigate software developed by Stora Enso which uses a multispectral imaging to map forest health. The mapping was made by using a drone with a multispectral camera, and the images from the flights were uploaded to the company's drone service.

This study focused on two spruce dominated forests in Lappeenranta, where spruces had been killed by bark beetle in previous years. Multispectral imaging and measurements were done in the summer of 2019. The study compared the observations made in the forest with the results of the program's health classification, and further program model was taught with reference material. After the training, the forest observations were compared with the results of the updated health classification. Tree health was graded on the scale of healthy-sick-dead.

After training the health classification model, the results of health classification of spruce improved from 71 % to 86 %. The best result was found in the identification of dead spruces, where model 2018 classified 96 % of the trees correctly and model 2019 100 % correctly. The study identified further development needs in improving tree detection and in the accuracy of classifying diseased trees. Based on the results, caution can be observed in the health classification, whereby a diseased tree may be incorrectly classified as healthy. However, based on the study, the health classification program of Stora Enso can be used to assess the health of spruce forest.

Language

Finnish

Pages 48

Keywords

European spruce bark beetle, remote sensing, unmanned aerial vehicle, drones

Sisältö

1	Johdanto	5
2	Kirjanpainaja	6
2.1	Kirjanpainajan ekologia.....	6
2.2	Kirjanpainajan torjunta	8
3	Kaukokartoitus	10
3.1	Sähkömagneettinen säteily.....	10
3.2	Ominaisheijastus tutkimuskohteena	12
3.3	Fotogrammetria	14
4	Miehittämättömät ilma-alukset	15
4.1	Droonien lainsäädäntö	15
4.2	Dji Phantom 4 Pro ja Micasense RedEdge -Mx	17
5	Hyönteistuhojen kaukokartoitus metsissä	19
5.1	Kaukokartoituksen käyttö kirjanpainajatuhojen kartoituksessa	19
5.2	Stora Enson kehitystyö droonien hyödyntämiseen	20
6	Tutkimuksen tarkoitus	21
7	Tutkimuksen toteuttaminen	22
7.1	Maastotutkimukset	22
7.2	Kuvausten suorittaminen	24
7.3	Kuvien lataus	25
7.4	Tulosten analysointi	27
8	Tutkimusolettamukset	28
9	Tulokset ja niiden tulkinta.....	29
9.1	Aineisto	29
9.2	Kuvien laatu	31
9.3	Puiden tunnistaminen ja puulajitulkinta.....	35
9.4	Terveysluokittelu	37
9.5	Tulosten tarkastelu	43
10	Pohdinta.....	45
10.1	Johtopäätökset	45
10.2	Jatkokehitystarpeet.....	46
10.3	Luotettavuus	47
	Lähteet	49

1 Johdanto

Informaatioteknologian kehitys on ollut osa suomalaista metsäpolitiikkaa alusta pitäen. Metsien inventointi aloitettiin Suomessa jo lähes sata vuotta sitten, ja tutkimusaineiston kattavuus on ainutlaatuinen koko maailmassa. (Luke 2015.) Tekniikan kehittyminen on johtanut jo aikaisessa vaiheessa kartta-aineistojen digitointiin, satelliittikuvien hyödyntämiseen ja paikkatietojärjestelmien käyttöönottoon metsäorganisaatioissa. Ensimmäiset kerätyt laserkeilausaineistot kattavat Suomessa ja muissa Pohjoismaissa jo lähes koko pinta-alan, ja uusi kierros on käynnistymässä. Satelliittikuvien korkea resoluutio sekä hyper- ja multispektrikuvaus antavat lisäinformaatiota metsävaroista. Näiden teknologioiden avulla metsäorganisaatiot kehittävät uusia palveluita omaan käyttöön sekä metsänomistaja-asiakkaille. (Holopainen 2019.)

Ilmaston lämpenemisen myötä hyönteis- ja myrskytuhojen riskit kasvavat Suomen metsissä. Kirjanpainaja ja muut kaarnakuoriaiset eivät ole vielä tehneet Suomessa suuria tuhoja, mutta paikallisesti niiden lisääntyminen aiheuttaa metsänomistajille taloudellisia vahinkoja. Talvien lyhentyminen ja roudan puuttuminen maaperästä lisäävät talvisia myrskytuhoja. Lämpimät kesät mahdollistavat kaarnakuoriaisten useamman sukupolven lisääntymisen ja yhteisvaikutukset myrskyjen lisääntyessä kasvattavat riskejä metsätuhoihin. (Luke 2016, Viiri, Viitanen, Mutanen & Leppänen 2019.)

Tämän tutkimuksen aiheena on ”Kirjanpainajatuhojen kartoitus multispektrikameralla”. Tutkimuksessa testataan kuusien terveydentilaa kartoittavaa ohjelmaa, jota Stora Enso kehittää metsänomistaja-asiakkaille. Tutkimuksen avulla saadaan tärkeää tietoa kirjanpainajatuhojen kaukokartoituksessa käytettävän tekniikan luotettavuudesta sekä voidaan tuottaa opetusaineistoa ohjelman kehittämistä varten. Stora Enson tavoitteena on saada tuotantoon kirjanpainajatuhoja jo varhaisessa vaiheessa tunnistava ohjelma, jolloin kirjanpainajien aiheuttamaa taloudellista tappiota on mahdollista pienentää. Drooni-lennokkien yleistyessä ja

tekniikan tullessa edullisemmaksi niiden käyttöpotentiaalia tutkitaan monelta kantilta. Tutkimus on osa yrityksen drooneihin liittyvää kehityshanketta, jonka tavoitteena on kehittää uusia palveluita metsäasiantuntijoiden avuksi ja metsänomistajien tulevaisuuden tarpeisiin. Opinnäytetyön toimeksiantajana toimii Stora Enso ja yhtiön edustajana toimii kehityspäällikkö Pekka Alajärvi.

2 Kirjanpainaja

2.1 Kirjanpainajan ekologia

Kirjanpainaja (*Ips typographus*) on kuusen (*Picea abies*) nilakerroksessa elävä noin 5 mm:n pituinen kaarnakuoriainen, joka ensisijaisesti iskee heikentyneisiin tai äskettäin kuolleisiin kuusiin (kuva 1). Lajia esiintyy koko Suomessa yleisesti, mutta suuria massatuhoja ei meillä ole päässyt syntymään. Kirjanpainajakannan pysyessä vakaalla tasolla kirjanpainajat pääsevät iskeytymään vain valmiiksi heikentyneisiin tai vaurioituneisiin puihin.

Yksittäisissä metsissä kirjanpainajakanta voi nousta epidemiatasolle, jolloin populaation runsas määrä mahdollistaa myös terveiden puiden sairastumisen. Kannan runsastumiseen vaikuttavat tuoreiden tuulenkaatojen määrä, elävien puiden heikentyminen sekä ilmasto-olosuhteet. Myrskytuhojen jälkeen kirjanpainajariski kasvaa sitä suuremmaksi, mitä enemmän kaatunutta kuusta jää metsään. Lisäksi kirjanpainaja selvästi hyötyy pitkistä hellejaksoista ja kuumista kesistä. (Uotila, Kasanen & Heliövaara 2015, 66 - 68; Kankaanhuhta 2014; Karttunen 2014.)



Kuva 1. Kirjanpainaaja *Ips typographus* (Schmutzenhofer Heinz 2002).

Kirjanpainajat parveilevat Suomessa touko-kesäkuussa maan lämpötilan ollessa vähintään +9 - 12 astetta, ja ilman lämpötila ylittää +18 - 20 astetta. Parveilussa koiraat iskeytyvät kuusen paksun kaarnan alle ja erittävät naaraiden houkuttelemiseksi feromoneja. Parittelun jälkeen naaraat kaivertavat omat emokäytävänsä puun pituussuunnassa nilakerrokseen, joiden reunoille ne laskevat munansa. Kirjanpainajat työntävät käytävillä syntyneen ruskean purun koiraan tekemästä sisäänmenoaukosta ulos, jolloin syntyy ihmissilmällä havaittavia ensimerkkejä kirjanpainajan iskeytymisestä. (Kankaanhuhta 2014.)

Munien kuoriuduttua toukat alkavat syömään omaa käytäväänsä nilaan puun poikkitaissuunnassa. Toukkien seurauksena syntyy helposti tunnistettava syömäkuvio, joka muistuttaa kaksipuoleista kampa (kuva 2). Koteloitumisvaiheen jälkeen kuoriutuu uusia aikuisia, jotka vielä jatkavat nilan syöntiä kuoren alla. Heinäkuun ja elokuun vaihteessa suurin osa aikuisista poistuu kuoren alta ja siirtyy etsimään talvehtimispaikkaa karikkeesta. Pieni osa aikuisista voi myös jäädä talvehtimaan puun tyvelle kaarnan alle. (Kankaanhuhta 2014)



Kuva 2. Kirjanpainajan toukkien tekemä syömäkuvio (Annala Erkki 2002).

Toukkien tekemät syömäkuviot katkaisevat puun kaarnan alla nilakerroksessa kulkevat nestevirtaukset, jonka takia puussa ei pääse vesi virtaamaan ja puu alkaa kuivua. Kirjanpainaja tuo mukanaan puuainekseen sinistäjäsienen, joka myös haittaa ravinteiden ja nesteen virtausta. Sinistäjäsieni nimensä mukaisesti värjää puuta sinertäväksi ja pilaa puutavara-ainesta. (Kankaanhuhta 2014.)

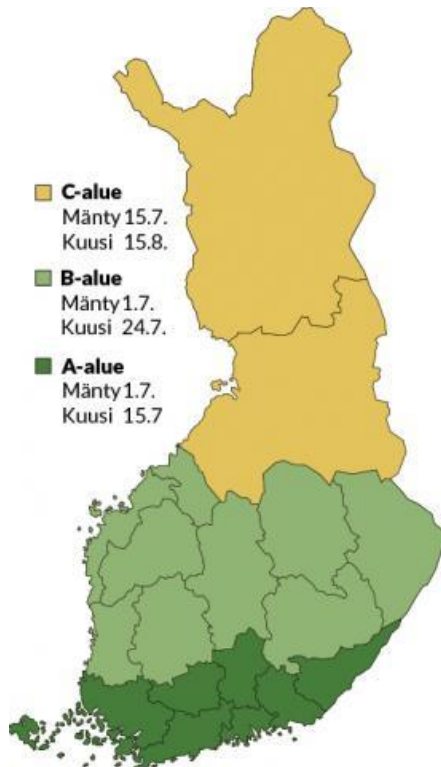
2.2 Kirjanpainajan torjunta

Koska kirjanpainajakanta on Suomessa yleinen, on tärkeää pyrkiä välttämään kannan kasvamista epidemiaksi saakka. Maanomistaja voi pyrkiä hallitsemaan kannan kokoa viemällä tuoreen kuusipuutavaran pois metsistä. Kirjanpainajan iskemät kuuset voi myös kuoria. Tuoreen kuusipuutavaran, kuten hakattu puu ja tuulenkaadot, on korjattava pois metsästä ja sen välittömästä läheisyydestä ennen uuden sukupolven aikuistumista. (Uotila ym. 2015, 68.)

Korjuun aikarajat ja asetukset löytyvät metsätuhoja koskevasta lainsäädännöstä. Lain metsätuhojen torjunnasta (1087/2013) mukaisesti puutavaran omistajan on kuljetettava puutavara pois hakkuupaikalta ja välivarastolta kuusen osalta seuraavasti:

edellisen vuoden syyskuun 1 päivän ja kuluvan vuoden toukokuun 31 päivän välisenä aikana kaadettu kuusipuutavara kuljetetaan pois hakkuupaikalta ja välivarastosta A-alueella viimeistään 15 päivänä heinäkuuta, B-alueella viimeistään 24 päivänä heinäkuuta ja C-alueella viimeistään 15 päivänä elokuuta (3. §.)

Kuvan 3 mukaisesti A-alue kattaa eteläisimmän Suomen, B-alue kattaa keskisen Suomen ja C-alue kattaa pohjoisimman Suomen.



Kuva 3. Suomen jakautuminen eri vyöhykkeisiin lain metsätuhojen torjunnasta mukaisesti (Metsäkeskus 2019).

Kirjanpainajien torjunnan kannalta yksittäisten tuulenkaatojen korjaaminen pois metsästä ei ole tarpeellista. Toimenpiteisiin on syytä ryhtyä vasta tilanteessa, jos metsään syntyy tuoretta torjuntakyvytöntä puuta yli 10 m³/ha. Aiemmin kuolleet, jo kuivuneet kuuset on syytä jättää metsään metsäluonnon monimuotoisuuden säilyttämiseksi. Näissä puissa voi myös elää kirjanpainajan luontaisia vihollisia tai kilpailijoita. Kirjanpainajia voi myös pyydystää feromoniansoilla, mutta niiden teho tuhojen torjunnassa on heikko. Ansat toimivat tutkimuskäytössä hyvin ilmentämään kannan kokoa. (Uotila ym. 2015, 68.)

3 Kaukokartoitus

3.1 Sähkömagneettinen säteily

Kaukokartoitus (Remote Sensing) on kohteen tutkimista ja mittaamista etäältä käyttäen avuksi sähkömagneettista säteilyä. Kaukokartoitusta voidaan tehdä passiivisin ja aktiivisin menetelmin. Passiivisessa kaukokartoituksessa kerätään kohteiden lähettämää tai heijastamaa säteilyä, kun taas aktiivisessa kaukokartoituksessa käytetään omaa säteilylähdettä, esimerkiksi tutkaa. Kaukokartoituksen etuja ovat mm. laajojen alueiden kartoittaminen samanaikaisesti sekä numeerisen analyysin avulla saatava objektiivinen, arvioijasta riippumaton tulos. (Kangas, Päivinen, Holopainen & Maltamo 2003, 121.)

Kaukokartoituksessa tietoa kerätään sähkömagneettisesta säteilystä. Se on poikittaista aaltoliikettä sähkökentässä ja ympäröivässä magneettikentässä, ja se leviää valonnopeudella. Esimerkiksi ihmissilmän havaitsema valo on osa sähkömagneettisen säteilyn spektriä. Valon nopeuden ollessa vakio säteilyn frekvenssi eli taajuus pienenee aallonpituuden kasvaessa. Pitkäaaltoisen säteilyn taajuus on siten pienempi kuin lyhytaaltoisen säteilyn. (Kangas ym. 2003, 122.)

Laskukaava 1. Sähkömagneettisen säteilyn kaavat (Pukkala 1985).

$$c = \lambda \cdot f, \quad (3.1)$$


$$\lambda = \frac{c}{f}$$

$$f = \frac{c}{\lambda}$$

jossa λ = aallonpituus
 f = frekvenssi eli taajuus
 c = valon nopeus (vakio).

Sähkömagneettisen kaikkia eri aallonpituusalueita kutsutaan sähkömagneettiseksi spektriiksi. Näkyvää valoa ovat aallonpituusalueet 380 - 730 nm. Näkyvää

valo lyhyemmät aallonpituusalueet ovat gamma, röntgen ja UV. Pidempiä aallonpituusalueita ovat infra, mikroaallot sekä radioaallot (kuvio 1). Auringon säteilyä heijastavia aallonpituusalueita ovat näkyvän valon lisäksi ns. lähi-infra (NIR), ja näitä käytetään eniten hyödyksi kaukokartoituksessa. (Kangas ym. 2003, 123.)



Kuvio 1. Sähkömagneettisen spektrin jakautuminen eri aallonpituusalueisiin. (Wikimedia Commons 2019).

Fysiikan lakien mukaisesti energia ei häviä, vaan sähkömagneettinen säteily heijastuu, absorboi (eli imeytyy) tai läpäisee kohteen. Sen voidaan esittää kaavalla:

Laskukaava 2. Saapuvan säteilyenergian kaava (Pukkala 1985).

$$E_i = E_r + E_a + E_t \quad (3.2)$$

jossa

- E_i = saapuvan säteilyn energia
- E_r = heijastuneen säteilyn energia
- E_a = absorboituneen säteilyn energia
- E_t = kohteen läpäisseen säteilyn energia.

Jolloin jokaiselle aallonpituudelle saadaan selville heijastussuhde:

Laskukaava 3. Heijastussuhteen laskukaava (Pukkala 1985).

$$R = \frac{E_r}{E_i} \quad (3.3)$$

3.2 Ominaisheijastus tutkimuskohteena

Kaukokartoitus perustuu tietoon, miten jokin tutkittava kohde emittoi (eli säteilee), absorboi tai heijastaa säteilyä. Tutkittava kohde, esimerkiksi puun latvus, muodostaa ominaisheijastuksen kuvaajan, josta havaitaan eri aallonpituusalueiden heijastussuhteet. Ominaisheijastukseen vaikuttavat kohteen ominaisuudet, mutta myös vuoden- ja vuorokaudenaika, säätila ja auringon korkeus. Nämä muuttujat tulee ottaa huomioon, kun tehdään kaukokartoituskuviin tulkintaa. Ominaisheijastuksen ollessa tunnettu, voidaan päätellä, tuleeko kohde erottumaan kuvilta, minkä sävyisinä se erottuu, sekä arvioida mitkä aallonpituusalueet ovat kyseiselle kohteelle optimaalisimmat kaukokartoitukseen. Näiden tietojen avulla voidaan valita kuvaukseen parhaiten soveltuva ajankohta sekä tehdä kuvien tulkinnan yhteydessä päätelmiä kohteen poikkeamista, kuten ravinnepuutoksista tai sairauksista. (Kangas ym. 2003, 124-125, Pukkala 1985,18-19.)

Koska kaikilla eri kohteilla on erilainen ominaisheijastus, pystytään kuvalta tunnistamaan eri kohteita. Metsän kaukokartoituksessa tärkeä havainto on siinä, että havu- ja lehtipuiden ominaisheijastus on näkyvän valon alueella suunnilleen samanlaista, mutta lähi-infran alueella eroavaisuus on suuri. Tämän johdosta lähi-infraa (NIR) käytettäessä pystytään erottamaan lehti- ja havupuut. (Pukkala 1985, 19.)

Muutokset heijastuksen säteilyssä on nähtävissä, kun aallonpituusalueet kuvataan omille kaistoilleen. Tavallisella kameralla, esim. matkapuhelimen kameralla, kuvaaminen tapahtuu yhtenä kaistana näkyvän valon aallonpituusalueella. Tästä kamerasta käytetään nimitystä RGB, mikä tulee lyhenteestä Red-Green-Blue. Kun kamerassa on useampia eri aallonpituusalueita (kaistoja), ja ne on erotettu toisistaan, on kyse multi- tai hyperspektrikamerasta. Multispektrikamerassa on usein alle 10 erillistä kaistaa, mutta hyperspektrikamerassa näitä kaistoja voi olla

jopa satoja. Multispektrillä kuvattaessa yksittäisen kaistan leveys on tavallisesti 10–40 nm, kun taas hyperspektrikameran kaistojen leveys usein 1 nm. (Kotala 2019, 30.)

Kasvillisuuden ominaisheijastuksen vaihtelut eri aallonpituusalueilla mahdollistavat hyper- ja multispektrikameralla kerätyn datan tulkintaa lukuisiin eri tutkimuksiin. Näkyvän valon aallonpituusalueilla ominaisheijastus muodostuu lehtien pigmenttien mukaisesti (esimerkiksi klorofylli eli lehtivihreä). Lähi-infran alueella 0,7 – 1,2 µm heijastussuhteeseen vaikuttaa lehden rakenne, eli mesofyllisolukon ilmatila. Tämä vaihtelee paljon kohteesta riippuen, joten sen avulla saadaan hyvin tietoa kohteiden eroista. Solukon vesipitoisuus eli veden absorptio vaikuttaa eniten ominaisheijastukseen aallonpituusalueilla 1,2 – 2,7 µm. Jotta kohteen heijastussuhteesta voidaan tehdä päätelmiä, tarvitaan jokin heijastusominaisuuksiltaan tunnettu referenssisäteilijä. (Pukkala 1985, 20-21.)

Kaukokartoituksessa mitataan tutkittavasta kohteesta heijastuvaa säteilyä. Riippuen kohteen pinnasta, heijastuva säteily voi olla diffuusia (hajoavaa), peilimäistä tai näiden kahden sekoitusta. Jos pinta on karkea, syntyy siitä enemmän diffuusista säteilyä kuin sileämmästä kappaleesta. Myös aallonpituuden pituus vaikuttaa karkeuden havaitsemiseen: pitkät aallot heijastuvat epätasaisistakin pinnoista peilimäisesti. (Pukkala 1985, 22.)

Näsi (2014, 7) kertoo vihreiden kasvien absorboivan lähes kaiken näkyvän valon aallonpituusalueella olevan säteilyn yhteyttääkseen. Vihreän valon alueella n. 550 nm:n kohdalla heijastavuus on suurempaa kuin absorptio, minkä takia näemme kasvit vihreinä. Aallonpituuden vaihtuessa näkyvästä valosta lähi-infraksi syntyy jyrkkä nousu heijastavuuden lisääntyessä, ja tätä kapeaa aallonpituusaluetta kutsutaan punaiseksi reunaksi, *red edge*. Kotalan (2019) mukaan kasvustojen heijastussäteily on sitä voimakkaampaa lähi-infrapunan ja näkyvän valon vihreän aallonpituusalueilla, mitä elinvoimaisempi kasvi on. Kuolleen ja kuivan kasvuston heijastussuhde kasvaa lineaarisesti 400 nm:n kohdalta 12 %:sta 800 nm:n kohdalle 40 %:iin.

Näiden tietojen perusteella voidaan päätellä, että puun terveyttä kartoitettaessa lähi-infran aallonpituusalueet sekä vihreän aallonpituuden alue olevan olennaisia tutkimuskohteita.

3.3 Fotogrammetria

Fotogrammetrialla tarkoitetaan kohteen mittaamista kolmiulotteisesti siitä otettujen kuvien avulla. Käytetyin fotogrammetrian käyttökohde on ilmakekuvaus, joka on osa kaukokartoitusta. Tutkittavalta alueelta otetaan samalta korkeudelta kuvia niin, että ne kattavat tasaisesti koko alueen ja jokainen maastonkohta löytyy vähintään kahdelta eri kuvalta. Vierekkäisten kuvien päällekkäiseltä alueelta, peittoalueelta, nähdään kohteissa pieni siirtymä kuvien välillä. Tämän siirtymän perusteella voidaan päätellä yksittäisten kohteiden etäisyyksiä toisiinsa ja määrittää niiden sijaintia myös kolmiulotteisesti. Näitä vierekkäisiä kuvia kutsutaan stereokuvapareiksi. (Ullakko 2015.)

Peräkkäisistä stereokuvapareista syntyy kuvajono, ja vierekkäisistä jonoista syntyy kuvamosaiikki. Mosakoinnissa kuvat kohdistetaan osittain päällekkäin niin, että syntyvän ilmakekuvan perspektiivi olisi mahdollisimman kohtisuoraan taivasta kohti. Kuvien reuna-alueet, joissa puut näkyvät vinossa, leikataan pois. (Uitto 2017.) Mosakoinnilla saadaan kaikkien puiden latvat osoittamaan kohti taivasta eikä kuvassa esiinny vinoumia.

Kuvauskorkeus vaikuttaa yksittäisiin kuviin siten, että korkealta otetuissa kuvissa kuvan reuna-alueen vääristymän osuus on pienempi verrattuna matalalta otettuun kuvaan. Täten matalalla kuvattaessa puut ovat vain pieneltä alueelta yksittäisen kuvan keskellä suorassa ja siksi kuvia pitää ottaa tiheästi. Korkealta kuvattaessa kuvien kokonaismäärä on pienempi ja silti kuvaparien peittävyys on suuri.

4 Miehittämättömät ilma-alukset

Droonit ovat kauko-ohjattavia miehittämättömiä ilma-aluksia, jotka voivat käyttö-tarkoituksensa mukaan olla hyvinkin erikokoisia ja -rakenteisia. Drooneista käytetään lyhennettä UAV, joka tulee englanninkielisistä sanoista *unmanned aerial vehicle*. Droonit ovat olleet pitkään käytössä tiedustelu- ja valvontatehtävissä sotilastarkoituksissa, mutta laitteiden yleistyessä niitä käytetään myös yleisemmin myös siviilitarkoituksissa. Ominaisuuksiensa johdosta droonit ovat hyödyllisiä mm. valvonta-, etsintä- ja kartoitustehtävissä. Metsien kartoitukseen droonit soveltuvat kokonaiskustannusten perusteella paremmin kuin lentokoneet, kun tavoitteena on kartoittaa pienehköjä alueita kerralla. (Tuominen, Balazs, Saari, Pölonen, Sarkeala & Viitala 2015, 277.)

4.1 Droonien lainsäädäntö

Droonin käyttöä kaupallisessa käytössä ohjaa ilmailulainsäädäntö (ilmailulaki 864/2014) ja Liikenteen turvallisuusviraston (Trafi) määräys OPS M1-32 ”Kauko-ohjatun ilma-aluksen ja lennokin käyttäminen ilmailuun”. Määräyksen mukaan drooni määritellään kauko-ohjatuksi ilma-alukseksi, jos sitä käytetään kaupalliseen tarkoitukseen, ja lennokiksi, jos käyttötarkoitus on harraste- tai urheilukäyttö. (Trafi 2018.) Kaikki metsien inventointiin tai kaukokartoitukseen käytettävät dronelennot kuuluvat siten kaupalliseen tarkoitukseen.

Määräyksen mukaan kauko-ohjatun ilma-aluksen käyttäjän on tehtävä toimijailmoitus Trafille, josta ilmenee tiedot droonin käyttäjästä, tekniset tiedot lennokista, toiminnan laatu ja laajuus sekä tiedot, aiotaanko toimintaa harjoittaa tiheästi asutulla alueella tai väkijoukon yläpuolella ulkona. Lennot tulee suorittaa siten, että ympäristölle aiheutuvat vaarat ja meluhaitat ovat mahdollisimman minimaaliset. Lennot eivät saa vaarantaa, haitata tai estää viranomaisten toimintaa esimerkiksi onnettomuustilanteissa. Lennosta vastaavan henkilön tulee olla vähintään 18-vuotias, ja ilma-aluksesta on käytävä ilmi käyttäjän nimi ja yhteystiedot.

Kaupallisessa käytössä olevan ilma-aluksen lennoista tulee pitää lentopäiväkirjaa, josta ilmenee seuraavat tiedot:

- a) lennon päivämäärä
- b) lennon lähtö- ja laskupaikka
- c) ilma-aluksen päällikkö
- d) ilma-aluksen valmistaja ja malli
- e) lennon tai lentosarjan alkamis- ja päättymisaika
- f) onko kyseessä:
 - a. suoraan näköyhteyteen perustuva toiminta (VLOS) vai
 - b. suoran näköyhteyden ulkopuolella tapahtuva toiminta (BVLOS)
- g) lentotehtävän luonne sekä maininta mahdollisesta kauko-ohjaukseen käytöstä.

Tietoja suoritetuista lennoista tulee säilyttää kahden vuoden ajan.

Lennon aikana dronin on oltava näköyhteydessä joko lennättäjän itse nähtävänä tai avustetusti. Avustetussa ilmatilan tarkkailussa toinen henkilö näkee dronin lennättäjän puolesta, jolloin heillä tulee olla luotettava viestintäyhteys toisiinsa. Ilma-alus tulee pitää koko ajan havaittavissa ja ohjattavissa, jolloin voidaan turvata muu ilmaliikenne ja ulkopuoliset henkilöt. (Trafi 2018.)

Jos alueella ei ole muita lentorajoituksia, on UAV:n maksimi lentokorkeus Suomessa 150 metriä. Lentokorkeutta rajoittavia alueita ovat mm. lentoasemien lähi-alueet (CTR, Control Zone), lentopaikan lentotiedotusvyöhyke (FIZ, Flight Information Zone) tai radiovyöhykkeet (RMZ, Radio Mandatory Zone). Alle kilometrin vaakasuoralla etäisyydellä kiitoradan reunasta lennättäminen dronella on kiellettyä. 1 - 3 km:n etäisyydellä kiitoradasta lentää voi ainoastaan kiinteän esteen välittömässä läheisyydessä. Yli 3 km:n etäisyydellä suojavao-ohjauksella maksimi-lentokorkeus on 50 metriä. Lennonjohto tai muu vastaava ilmaliikennepalvelun tarjoaja voi myöntää poikkeamia näihin ohjeisiin, mitä varten täytyy toimittaa etukäteen lentolupahakemus. Nämä samat määräykset koskevat myös lennokkien eli harrastekäytössä olevien dronien lennättämistä. (Trafi 2018)

Määräyksen mukaan tiheästi asutun alueen yläpuolella lentäminen on dronilla sallittua kun:

- a) ilma-aluksen suurin lentoonlähtömassa on enintään 3 kg ja ohjaaja on tutustunut alueeseen, varmistunut laitteen teknisestä kunnosta ja arvioinut, että lento voidaan suorittaa turvallisesti. Massaan ei lasketa ilma-alukseen kiinnitettävää pelastuslaitetta. Jos lentoonlähtömassa on yli 3 kg, mutta alle 7 kg, tulee ilma-aluksen käyttäjän laatia kirjallinen turvallisuusarviointi ja toimittaa se pyydettäessä Trafille.
- b) lento tapahtuu suorassa näköyhteydessä
- c) käytetään sellaista lentokorkeutta, että hätätilanteessa voidaan suorittaa lasku siten, että siitä aiheutuva vaara on ulkopuolisille ihmisille tai heidän omaisuudelleen mahdollisimman pieni.


4.2 Dji Phantom 4 Pro ja Micasense RedEdge -Mx

Tutkimuksessa käytettiin Dji Phantom 4 Pro-droonia (kuva 4). Dronin oma paino akun ja propellien kanssa on 1 388 g. Ilma-aluksen halkaisija on 350 mm ilman propelleja ja maksiminopeus 72 km/h eli 20 m/s. Akun maksimi lentoaika on noin 30 minuuttia ja käyttölämpötila koneella on 0–40 °C. Valmistaja lupaa laitteen pystyvän lentämään jopa 10 m/s tuulessa. Etäohjain toimii 2.400–2.483 GHz ja 5.725–5.825 GHz taajuuksilla. (DJI 2019.)



Kuva 4. Tutkimuksessa käytettiin DJI Phantom 4 Pro -droonia ja siihen liitettyä Micasense RedEdge-MX -multispektrikameraa (Markus Haapamäki 2019).

Tämän tutkimuksen kuvauksissa käytettiin Micasense RedEdge-MX -multispektrikameraa (kuva 4), jossa on viisi eri linssiä eri aallonpituusalueille (kuvio 2). RedEdge-MX ottaa samanaikaisesti kuvia sinisen (475 nm), vihreän (560 nm), punaisen (670 nm), punaisen reunan (RedEdge, 720 nm) sekä lähi-infrapun (NIR, 840 nm) aallonpituusalueilta. Punaisen ja punaisen reunan kaistojen pituus oli noin +/- 5 nm, sinisen ja vihreän kaistojen +/- 10 nm ja lähi-infrapunakaistan pituus oli +/- 20 nm. Multikameran paino on 231,9 g akun ja kaapeleiden kanssa.



Kuvio 2. Micasense RedEdge-MX multispektrikameran viisi kuvattavaa aallonpituusalueita: blue, green, red, red edge ja near-infrared (NIR) (Micasense 2019).

5 Hyönteistuhojen kaukokartoitus metsissä

5.1 Kaukokartoituksen käyttö kirjanpainajatuhojen kartoituksessa

UAV-lennokeilla tehtävä hyperspektrikuvausteknologia mahdollistaa keräämään tietoa pienialaisesti puiden heijastuvuuden muutoksista (Näsi, Honkavaara, Lyytikäinen-Saarenmaa, Blomqvist, Litkey, Hakala, Viljanen, Kantola, Tanhuanpää, Holopainen & Edvard 2018). Tämän avulla voidaan kerätä hyvinkin yksityiskoh- taista tietoa puutasolla puiden terveydestä ja mahdollisista kirjanpainajaiskeyty- mistä. Näsin ym. (2018) tutkimuksessa hyperspektrikameralla aallonpituusalu- eilla 500–900 nm pyrittiin tunnistamaan kirjanpainajan sairastuttamia kuusia (*Picea abies*) ja luokitella ne terveydentilan mukaan. Kolmen luokan luokittelussa (terve, sairas, kuollut) paras kokonaistarkkuus oli 76 %, ja kahden luokan luokit- telussa (terve, kuollut) kokonaistarkkuus oli 90 %. Näsin mukaan korkearesoluu- tiainen hyperspektrikuvaaminen tulee antamaan erittäin hyvän käyttöarvon kir- janpainajatuhojen varhaisessa indikoimisessa. Pohjois-Amerikassa tehdyssä tutkimuksessa havaittiin kaarnakuoriaisten heikentämän kuusen neulasmassan heijastuskyvyn olevan suurempi näkyvän valon alueella ja pienempi lähi-infra- alueella (Näsi 2014, 13).

Myös Junttila (2019) on havainnut aktiiviseen monikanavalaserkeilausteknologi- aan perustavalla menetelmällä pystyvän tunnistamaan 90 % yleistarkkuudella kir- janpainajan iskeytymät puut ennen kuin latvus osoittaa visuaalisia heikentymisen merkkejä. Tutkimuksen mukaan neulasten vesipitoisuus laskee nopeasti kirjan- painajan iskeytymisen jälkeen. Junttila kertoo myös, että sinistäjänsienellä infek- toidut kuusen taimien neulaset menettivät vesipitoisuuttaan huomattavasti nope- ammin kuin kuivuuskäsitellyt kuusen taimien neulaset. Vesipitoisuuden havainnointiin soveltuvimmat aallonpituudet kyseisellä teknologialla oli 905 nm ja 1550 nm.

Multispektrikuvausta voidaan metsien terveyden kartoituksen lisäksi käyttää hyö- dyksi esimerkiksi maanviljelyssä. Teknologian avulla voidaan mm. havaita bio- massan määrää nurmiseoksessa ja kohdentaa kasvustotarkastukset paremmin

(Kotala 2019). Kotalan (2019) mukaan kasvien absorptio on voimakkaimmillaan näkyvän valon aallonpituuksilla (400–700 nm), joten heijastava säteily jää alle 10 prosenttiin saapuvasta sähkömagneettisesta säteilystä. Heijastussuhde nousee selvästi korkeammaksi aallonpituusalueilla 700–1400 nm (NIR), mutta jälleen laskee keskipitkän infrapunan alueella (1400–2500 nm).

5.2 Stora Enson kehitystyö dronien hyödyntämiseen

Stora Enso on kehittänyt ohjelmaa, jonka tarkoituksena on tunnistaa multispektrikameran keräämästä datasta kuusen terveydentilan (Korvenranta 2019). Multispektrikameran käyttö perustuu useiden samanaikaisesti kuvattujen kapeiden aallonpituusalueiden keräämän datan tulkintaan (Micasense 2019). Stora Enson ohjelma pyrkii tunnistamaan häiriintyneestä nestekierrosta kärsivän puun, joka voi olla merkki kirjanpainajien iskeytymisestä. Ohjelman kehitystyön tavoitteena on tunnistaa kirjanpainajan heikentämät puut, ennen kuin ihminen sen havaitsee. Varhaisella heikentymisen tunnistamisella voidaan ryhtyä toimenpiteisiin riittävän aikaisin, jotta mahdollinen epidemian alku saadaan pysäytettyä. Ihmissilmin havaittavissa oleva puun heikentyminen on nähtävillä selvimminkin kasvukauden loppupuolella, jolloin kirjanpainajapopulaation hillitseminen ei välttämättä enää tuota tuloksia (Näsi 2018).

Droonikuvien tulkitsemiseen ja analysointiin Stora Enso käyttää Agisoft-ohjelmistoa, jonka päälle yhtiö on kehittänyt omia sovelluksia. Stora Enso sisäisesti drooni tulkintaa kutsutaan drone-palveluksi. Agisoft-ohjelmiston päälle Stora Enso on rakentanut mm. kuvien lataussivuston ja kirjanpainajapuiden tulkitsemiseen tarvittavaa koneoppimisanalytiikkaa. Sovellusta käytetään tällä hetkellä yhtiön tuotantolaitoksilla varastoinventoinnissa. Tämä on lisännyt turvallisuutta, helpottanut työtä ja parantanut varastoinventoinnin tarkkuutta. (Korvenranta 2019.)

Kirjanpainajapuiden tunnistamista varten ohjelmaa on opetettu käyttämällä vuonna 2018 kerättyjä referenssiaineistoja kirjanpainajametsikoistä. Suurin osa vuoden 2018 referenssiaineistosta on kerätty Tšekeistä ja vain murto-osa Suo-

mesta. Referenssiaineiston laadussa on myös eroa, sillä suurin osa mallin opetusaineistosta perustuu ilmakehältä määritettyihin terveyslukituksiin. Jatkokehitystä varten, jotta ohjelma saadaan löytämään paremmin varhaisen vaiheen sairastuneet puut, tulee ohjelmaa vielä kehittää ja opettaa lisää. Korvenranta arvioi, että kehitystyö jatkuu seuraavinakin vuosina mallin terveyslukittelun parantamiseksi.

6 Tutkimuksen tarkoitus

Tutkimuksen tehtävänä on tutkia Stora Enson kehittämän ohjelman antaman terveyslukittelun paikkaansa pitävyyttä. Ohjelman lopullisiin laskentamalleihin tehtiin kesän 2019 koealatutkimusten perusteella vielä korjaavia laskentamalleja. Käytännössä tämä tarkoitti tutkimuksen yhteydessä referenssipuiden käyttämistä ohjelman opettamiseen. Tässä tutkimuksessa verrattiin vuoden 2018 tehdyn mallin toimivuutta vuoden 2019 päivitettyyn malliin. Tuloksia verrattiin myös vastaavien tutkimusten tuloksiin, josta voidaan tehdä päätelmiä ohjelman käyttöönottovalmiudesta. Tutkimus toteutettiin tapaustutkimuksena, jossa tarkasteltiin kirjanpainajan kohteeksi joutuneita metsikkökuvioita. Tämän tutkimuksen lisäksi mallin kehittämistä varten kartoituslentoja suoritettiin Stora Enson toimesta kesän 2019 aikana Tsekeissä ja Ruotsissa, joista myös kerättiin opetusaineistoa.

Tutkimuksen toivotaan tuottavan lisäarvoa myös yleisesti yhtiön droonien käyttöön liittyvän kehityshankkeen hyväksi. Stora Ensolla on droonien liittyvien hankkeiden lähtökohtana ollut pyrkiä saamaan mahdollisimman suuri hyöty kuluttajakäyttöhintaisista droneista, jotta niiden käyttö mm. metsäasiantuntijoiden työkaluina olisi kannattavaa.

Tutkimustehtävään kuului eri vaiheita: maastotutkimukset, lennätykset, kuvien laa-
taamisen jälkeen kuvatulkinta ja ohjelman opetus, ohjelman tulosten vertailu omiin maastotutkimuksiin sekä tulosten analysointi.

7 Tutkimuksen toteuttaminen

7.1 Maastotutkimukset

Maastotutkimukset toteutettiin heinä-syyskuussa 2019. Tutkimuskohteina oli kaksi 04-kehitysluokan kuusivaltaista metsikköä Lappeenrannan alueella. Kohteet valittiin paikallisten metsäasiantuntijoiden historiatietojen perusteella. Kohteilla on aiempina vuosina havaittu pystyyn kuolleita puita, ja tapahtuneen on arvioitu johtuneen kirjanpainajan iskeytymistä. Tutkimuskohteet nimettiin metsätilan nimen mukaan. Tutkimuskohde ”Tiehaara” sijaitsi Lappeenrannan Lempiälässä, ja lentokartoitus tehtiin siellä noin 3,1 ha metsikön alueella (kuva 5).



Kuva 5. Lempiälässä sijaitseva tutkimuskohde Tiehaara (Maanmittauslaitos 2019).

Tutkimusalue ”Huumarmäki” sijaitsi Lappeenrannassa Lensulassa (kuva 6). Siellä koealat sijaitsivat kuvassa x näkyvässä 1,5 ha metsikössä, jonka lisäksi lentokartoitusta tehtiin 4,5 ha metsikössä tien toisella puolella.



Kuva 6. Lensulassa sijaitseva tutkimuskohde Huumarmäki (Maanmittauslaitos 2019).

Ensimmäisellä tutkimuskäynnillä tutkittavista metsistä kartoitettiin puita, joihin kirjainpainaja on iskeytynyt. Puita tutkittiin silmämääräisesti, ja apuna iskeymäpuiden tunnistamisessa oli Luonnonvarakeskuksen tutkija Tiina Ylioja sekä tutkimusassistentti Leena Aarnio. Iskeymäpuut merkittiin maastossa kuitunauhalla ja ne numeroitiin. Iskeymäpuiden ympärille tehtiin ympyräkoeala (200 m²), jonka rinnankorkeudelta yli 15 cm:n kokoiset puut kartoitettiin, mitattiin ja numeroitiin juoksevalla luvulla. Puista kirjattiin seuraavat tiedot: puun numero, etäisyys ja suunta koealan keskipisteestä, puulaji, rinnankorkeusläpimitta sekä terveys. Joka neljännessä puusta mitattiin pituus. Koealan avulla tutkimukseen saatiin mukaan myös terveitä puita vertailtaviksi puiksi. Jokaisella mittauskäynneillä tutkittavista puista kirjattiin ylös silmämääräisesti arvioitu terveyden tila.

Puiden terveys luokiteltiin maastossa asteikolla 1-4 (terve, heikentynyt, sairaus, kuollut). Terve puu näyttää ulkoisesti hyvin voivalta. Puu määritellään terveeksi, jos ulkoisella tarkastelulla siitä ei havaita esim. pihkavuotoja, runkovaurioita, lumituhoja tai harsuuntumista. Heikentyneessä puussa on jokin edellä mainituista asioista, mutta puun yleiskunto näyttää vielä hyvältä. Esimerkiksi puu jonka latva on katkennut viimeisen vuoden aikana, mutta vihreä latvusosa on vielä runsas suhteessa puun kokoon, luokiteltiin heikentyneeksi. Jos puussa havaittiin useita

eri heikentymiseen vaikuttavia tekijöitä tai jokin yksittäinen havainto oli suuri, määriteltiin se sairaaksi. Esimerkiksi voimakkaasti harsuuntunut puu oli sairas. Kuolleeksi puu määriteltiin, jos siitä ei havaittu lainkaan vihreitä neulasia.

Tiehaaran tutkimuskohteella koealoja merkittiin maastoon yhteensä 7 kappaletta, ja niissä oli yhteensä 74 kpl koealapuita, joista alussa 56 kpl terveitä, 14 kpl heikentyneitä tai sairaita, ja 4 kpl kuolleita. Yhden sairaan puun luokitus muuttui mittauksen aikana kuolleeksi. Tiehaarassa ensimmäinen lennätys tehtiin 17.7. ja yhteensä onnistuneita lentoja oli kuusi. Huumarmäessä koealoja merkittiin yhteensä 6 kappaletta, joissa oli yhteensä 53 kpl puita. Terveitä puita oli alussa 30 kpl, heikentyneitä tai sairaita oli 20 kpl ja kuolleita 3 kpl. Yksi sairas puu luokiteltiin myöhemmässä mittauksessa kuolleeksi ja yksi terve puu heikentyneeksi. Huumarmäessä lennot aloitettiin 7. elokuuta ja siellä lentoja suoritettiin yhteensä 4 kertaa, joista kolmen lennon kuvat onnistuivat.

7.2 Kuvausten suorittaminen


Tutkimuslennot aloitettiin Tiehaarassa 17.7.2019, ja lennätyskierroksia tehtiin noin parin viikon välein. Yhteensä Tiehaarassa tehtiin 6 lentoa, joista mallin 2018 analysointiin saatiin 5 kuvausta ja mallin 2019 analysointiin 6 kuvausta. Viimeinen kuvauslento suoritettiin 11.9.2019, josta ei ehditty tehdä mallin 2018 terveystulkintaa. Huumarmäessä lennätyskierrokset aloitettiin 7.8.2019 ja siellä lentoja suoritettiin 4 kertaa. Onnistuneita kuvauksia oli 3. Viimeinen onnistunut kuvauslento suoritettiin 28.8.2019.

Lennot suunniteltiin etukäteen puhelimen Pix4Dcapture-sovelluksella. Lentosuunnitelmaan rajattiin kuvattava alue ja asetuksista määritettiin mm. lentonopeus sekä kuvien peittävyys. Lentonopeudeksi asetettiin toiseksi hitain vauhti, ja kuvien peittävyydeksi 90 %. Droonin ilmaan nostaminen tehtiin manuaaliohjauksella, jonka jälkeen lennätys tapahtui lentosuunnitelman mukaan automaattisesti. Drooni oli koko lennätysajan valvottavissa. Lentokorkeus oli tässä tutkimuksessa 120 metriä, jolloin multispektrikameran pikselikoko oli 8x8 cm.


Ennen lentoa lähtöä ja välittömästi droonin laskeuduttua multispektrikameralla otettiin kuva kalibroitipaneelista. Kalibroitipaneelin tarkoitus oli kalibroida kuvien valoisuus sen hetkisen valoisuuden mukaan. Kaikki lennot suoritettiin auringon ollessa korkeimmillaan, kello 10:45 ja 13:45 välillä.

7.3 Kuvien lataus

Kuvauskohterin multispektrikameran kuvat ladattiin Stora Enson omaan ohjelmistoon, joka loi kuvista ortokuvan. Ohjelmassa pystyy tarkastelemaan metsää RGB- sekä erilaisina multispektrikuvina. Kuvassa 7 kuolleet puut erottuvat muusta puustosta selvästi vihertävinä. (Kuvat 7 ja 8.)



Kuva 7. Multispektrikameran kuvasta muodostettu ilmakekuva (Stora Enso 2019).



Kuva 8. RGB- eli ns. "tavallinen" ilmakekuva (Stora Enso 2019).

Kuvien latauksen jälkeen ohjelmassa ajettiin ensin vuoden 2018 terveystuokitusmalli. Mallin antamia puiden terveystietoja verrattiin maastomittausten tuloksiin jokaisen lennon osalta. Vertailu suoritettiin visuaalisesti tarkasteltuna ohjelman tuottamilta ortokuvilta. Kuvista etsittiin mitatut koealat ja niihin kuuluvat puut. Jokaisen koealan puun osalta merkittiin, tunnistikko malli puuta, luokiteltiinko se oikeaksi puulajiksi ja mikä on mahdollinen terveystuokittelu mallin mukaan. Nämä tiedot kerättiin Excel-taulukkoon yhdessä puun koealamittaustietojen kanssa. Tässä vaiheessa mallin 2018 paikkaansa pitävyyttä saatiin tutkittua koko referenssipuuaineistolla. Näistä tehtiin analyysit, joita verrattiin vuoden 2019 mallin opetuksen jälkeisiin tuloksiin.

Maastossa mitatuista puista valittiin noin puolet, joita käytettiin terveystuokitusmallin opetusaineistona. Tästä opetetusta mallista käytetään nimitystä vuoden 2019 malli. Opetus tapahtui ohjelmaan syöttämällä maastosta tehtyjen havaintojen perusteella puiden terveystiedot asteikolla terve-sairas-kuollut. Maastossa määritellyt luokat 2 - 3 (heikentynyt ja sairaas) merkittiin ohjelmaan sairaaksi. Ohjelman käyttämää laskentamallia päivitettiin opetusaineiston syöttämisen jälkeen, ja terveystuokituksen tuloksia vertailtiin niihin referenssipuihin, joita ei ohjelmalle syötetty.

Vuoden 2018 mallia tutkittaessa käytössä oli se määrä vertailuaineistoa, mitä maastossa oli mitattu. Vuoden 2019 mallin tuloksia päästiin vertailemaan noin puoleen mitatuista puista, sillä puolet mitatuista puista oli käytetty mallin päivitykseen. Näiden mallien terveyslukittelusta laskettiin, kuinka suuri osa referenssi-puista määriteltiin samoin kuin maastossa.

7.4 Tulosten analysointi

Tuloksia tutkittiin kvantitatiivisin menetelmin. Ohjelman antamia puulajitunnistusta ja terveyslukituksia verrattiin maastossa mitattuihin koealapuihin. Laskemiseen ja aineiston käsittelyyn käytettiin Excel-ohjelmaa. Tulosten analysoinnissa käytettiin avuksi Pivot-ohjelman ristiintaulukointia. Tuloksista tarkasteltiin puiden löytymistä, niiden tunnistamista puulajin mukaan ja kuusien osalta terveyslukittelua. Terveyslukittelusta tarkasteltiin ns. recall ja precision -tunnuksia, sekä laskettiin Cohenin kappa -arvo. Recall-tunnus kertoo, kuinka hyvin maastossa esim. terveeksi luokitellut puut on mallien mukaan luokiteltu terveeksi. Precision-tunnus kertoo terveyslukittelun täsmällisyydestä, eli esimerkiksi miten mallin antamassa luokassa ”terve” puut ovat todellisuudessa maastomittausten mukaan terveitä. Cohenin kappa-arvo on tilastollinen luku, joka mittaa yksimielisyyttä huomioiden sattuman mahdollisuuden. Sen avulla voidaan esittää kahden eri arvioijan tekemää luokittelun yksimielisyyttä, kun he luokittelevat toisistaan riippumatta samoja havaintoja kahteen tai useampaan luokkaan (Siren 2008, 5). Kappa-arvo esitetään asteikolla -1–1, ja sen laskemiseen käytetään kaavaa:

$$k = \frac{p_0 - p_e}{1 - p_e} \quad (7.1)$$

jossa

k = kappa

p_0 = suhteellinen osuus, joka kuvaa yksimielisyyttä (accuracy)

p_e = luku, joka kuvaa sattumamielisuuden suuruutta, jossa oletetaan, että tulokset ovat riippumattomia toisistaan.

Cohenin kapin -arvo 1 kuvastaa täydellistä yksimielisyyttä, jolloin yksikään yhteneväinen tulos ei ole syntynyt sattumanvaraisesti. Kapan arvo 0 syntyy tilanteessa, jossa kaikki yhteneväiset tapaukset syntyvät arvauksella. Negatiivinen arvo kertoo tilanteesta, että yksimielisyys on heikompaa kuin sattuma. Yhteensä tutkimuksen aineistoa kertyi vuoden 2018 mallin tulosten analysointiin 529 havaintoa ja vuoden 2019 mallin analysointiin 345 havaintoa.

8 Tutkimusolettamukset

Stora Enson kehittämä terveyslukitteluohjelma perustuu koneoppimisanalytiikkaan. Ohjelma on ohjelmoitu tunnistamaan puun sijainnin, puulajin ja sitten luokittelemaan puunterveyden. Mallinnuksessa on tärkeintä saada sovellus ensin löytämään puun sijainti, jota varten se luo kuvasta 3-d -mallinnuksen. Ohjelman perustuessa koneoppimiseen on hyvien referenssiaineistojen käyttö avainasemassa. Ohjelmalle on vuoden 2018 kerättyjen referenssipuiden kuvia opetettu, ja niiden avulla se etsii vastaavanlaisuuksia muilta kuvilta. Koska vuoden 2018 aineisto on keskieurooppalainen, oletetaan tulosten toimivan siellä paremmin kuin Pohjoismaissa. Tämä siksi, että metsien rakenne ja puustosuhteet poikkeavat pohjoismaisista metsistä. Kun ohjelmalle syötetään opetusaineistona vuoden 2019 aikana kuvattuja Suomen ja Ruotsin kohteita, oletetaan että terveyslukittelu onnistuu siellä paremmin kuin vuoden 2018 mallia käytettäessä. (Korvenranta 2019)


Junttila (2019) totesi omassa tutkimuksessaan kasvin nestepitoisuuden havainnointiin sopivimmat aallonpituusalueet olevan 905 nm ja 1550 nm. Stora Enson käyttämässä multispektrikamerassa kuvattava aallonpituusalue jää noin 840 nm:iin, jolloin Junttilan havainnot jäänevät huomaamatta. Toisaalta Junttilan tutkimuksissa käytettiin aktiivista kaukokartoitusta, joten tekniikoita ei voi täysin verrata keskenään. Näsi (2018) puolestaan käytti omassa tutkimuksessaan aallonpituusalueena 500-900 nm, jotka ovat lähellä tämän tutkimuksen käytettäviä aallonpituusalueita.

Junttilan ja Näsin tutkimuksissa todettiin multispektrikuvauksen toimivan kirjainpainajapuiden tunnistamiseen, kun käytetään riittävän tarkkaresoluutioista kuvausvälineistöä. Tässä tutkimuksessa käytetään huomattavasti edullisempaa droonia, sekä multispektrikameran pikselikoko on isohko. Vuoden 2018 malliin kehittämiseen käytetty aineisto on kerätty toisella droonilla ja multispektrikameralla, joka Korvenrannan mukaan voi johtaa omiin vääristymiin käytettäessä tämän vuoden droonia ja kameraa.

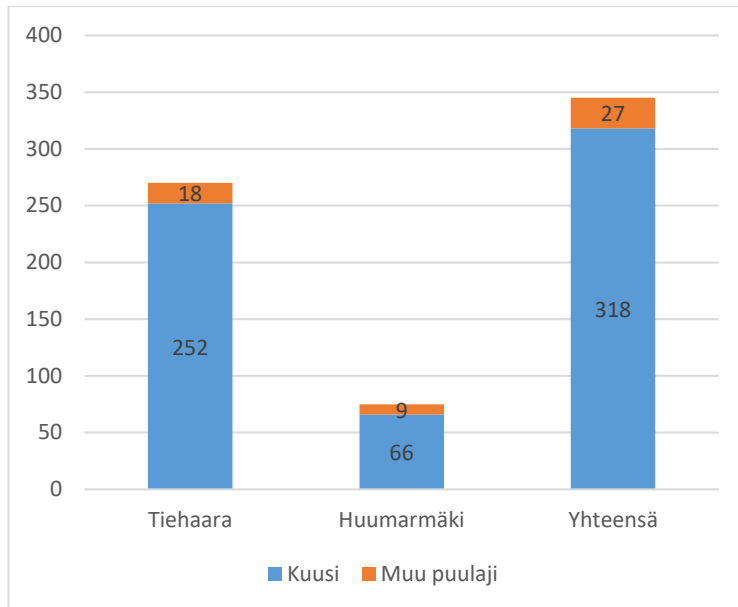
9 Tulokset ja niiden tulkinta

9.1 Aineisto

Tiehaarassa koealoilla oli yhteensä puuta 74, joista opetuskäyttöön valittiin 29 puuta. Huumarmäessä puuta oli koealoilla yhteensä 53, joista opetuskäyttöön otettiin 28. Yhteensä aineiston kooksi kertyi vuoden 2018 mallin tulosten analysointiin 529 puuta (Tiehaara 370, Huumarmäki 159) ja vuoden 2019 mallin analysointiin 345 puuta (Tiehaara 270, Huumarmäki 75). Kuusien osuus aineistosta oli vuoden 2018 mallissa 90 % ja 2019 mallissa 92 % (kuvio 3 ja 4).




Kuvio 3. Vuoden 2018 mallin aineisto puulajeittain.




Kuvio 4. Vuoden 2019 mallin aineisto puulajeittain.

Läpimittaluokittain tarkasteltuna yleisin oli 21 – 30 cm luokka, joiden osuus oli molemmissa aineistoissa 47 % aineistosta. Mallin 2018 aineistossa (n=529) seuraavaksi suurin osuus oli 31 – 40 cm luokka (30 %), toiseksi pienin luokka oli 15 – 20 cm luokka (17 %) ja pienin osuus aineistossa oli yli 40 cm puiden luokka (6 %). Mallin 2019 aineistossa 31 – 40 cm kokoisia puita oli 33 %, 15 – 20 cm puita 15 % ja yli 40 cm puita 5 % (kuviot 5 ja 6).



Kuvio 5. Mallin 2018 tutkittava aineisto läpimittaluokittain (n=529).




Kuvio 6. Mallin 2019 tutkittava aineisto läpimittaluokittain (n=345).


9.2 Kuvien laatu

Silmämääräisesti tarkasteltuna ensimmäinen havainto mallin ilmakuviista oli, että kaikki koealojen puut eivät näy tai niitä ei ole tunnistettu kuvasta. Saman koealan eri lennoilta oli erotettavissa eri puita ja osittain jopa puolet puista ei näkynyt visuaalisesti. Kuvien laadussa oli selkeitä eroja riippuen sääolosuhteista, mutta edes olosuhteiltaan parhaassa kelissä kuvatulla lennolla ei kaikkia puita näy Agisoft-ohjelmiston koostamalta ilmakuvasta. Osa puista näkyi visuaalisesti tarkasteltuna, mutta silti malli ei niitä tulkinnut puiksi.

Kuvista 9 ja 10 voidaan havaita, että sama alue toistuu eri lennoilla erilaisena visuaalisena kuvana, ja malli ei myöskään tunnista puiden määrää ja sijaintia toisiinsa yhtäläisesti. Kuvassa 10 oikeassa yläkulmassa puiden latvat ovat sekoituneet, ja malli tunnistaa vähemmän puita kuin kuvassa 9. 11.9. otetussa kuvassa näkyy myös selvästi, miten kuvien yhdistämisessä syntyneet virheet aiheuttavat puiden yhdistymistä tai latvusten katoamista. Todellisuudessa molemmista kuvista puuttuu koealalla mitattuja puita.




Kuva 9. 19.8. kuvattu lento mallin 2019 puulajitulkinnalla. Selitykset: vihreä kolmio = kuusi, harmaa pallo = muu puulaji (Stora Enso 2019).




Kuva 10. 11.9. kuvattu lento mallin 2019 puulajitunnistuksella. Selitykset: vihreä kolmio = kuusi (Stora Enso 2019).

Kuvien laatu vaihteli eri lentokertojen välillä paljon. Sääolosuhteet vaikuttivat kuvien laatuun merkittävästi. Paras kuvan laatu saatiin, kun kuvaus suoritettiin pilvisellä säällä. Kuvien laatua heikensi aurinkoinen tai puolipilvinen sää sekä kova tuuli. 26.7. kuvattu lento ylivalottui voimakkaasti, johtuen kirkkaasta kelistä ja kalibrointipaneelilla olevasta ruohon korren varjosta. Vuoden 2018 mallissa (kuva 11) ylivalottuneesta kuvasta kadonneiden tai ei puuksi luokiteltujen puiden osuus oli peräti 74 %. Ylivalottuneessa kuvassa suurin osa puista tunnistettiin ”muu kuin puu” -merkinnällä, ja valtaosa kuusista merkittiin muuksi puulajiksi. Vuoden 2019 mallissa kaikki koealojen puut löytyivät ja tulkittiin puiksi, kuten kuvasta 12 voidaan havaita.




Kuva 11. Ylivalottuneen kuvan (26.7.) puulaji- ja terveystulkinta vuoden 2018 mallilla. Selitykset: harmaa neliö = muu kuin puu, turkoosi pallo = muu puu laji, vihreä pallo = terve kuusi, keltainen pallo = sairastunut kuusi, punainen pallo = kuollut kuusi (Stora Enso 2019).



Kuva 12. Ylivalottuneen kuvan (26.7.) puulajitulkinta vuoden 2019 mallilla. Selitykset: vihreä kolmio = kuusi, vaalean vihreä kolmio = mänty, keltainen salmiakkikuvio = koivu, harmaa pallo = muu puulaji (Stora Enso 2019).

Osalla lennoista ilmakehuvaan syntyä vääristymiä ja vinoumia. Puiden latvukset saattoivat olla osassa kuvaa kuvattu oikein ylhäältä alaspäin, mutta osa sivuviis-
tosta. Kuvassa 13 näkyy, miten vinossa olevia puita ei mallin 2019 puulajitulkin-
nassa tunnisteta välttämättä puuksi lainkaan.




Kuva 13. Mallin 2019 puulajitulkinta. Voimakkaasti vinossa olevia puita malli ei tunnista. Selitykset: vihreä kolmio = kuusi, harmaa pallo = muu puulaji (Stora Enso Metsä 2019).

Kuvien laatua heikentäviä tekijöitä pyrittiin minimoimaan lentojen suunnittelulla keliolosuhteiden mukaan ja asettamalla mahdollisimman optimaaliset asetuksen droonin lento-ohjelmaan.

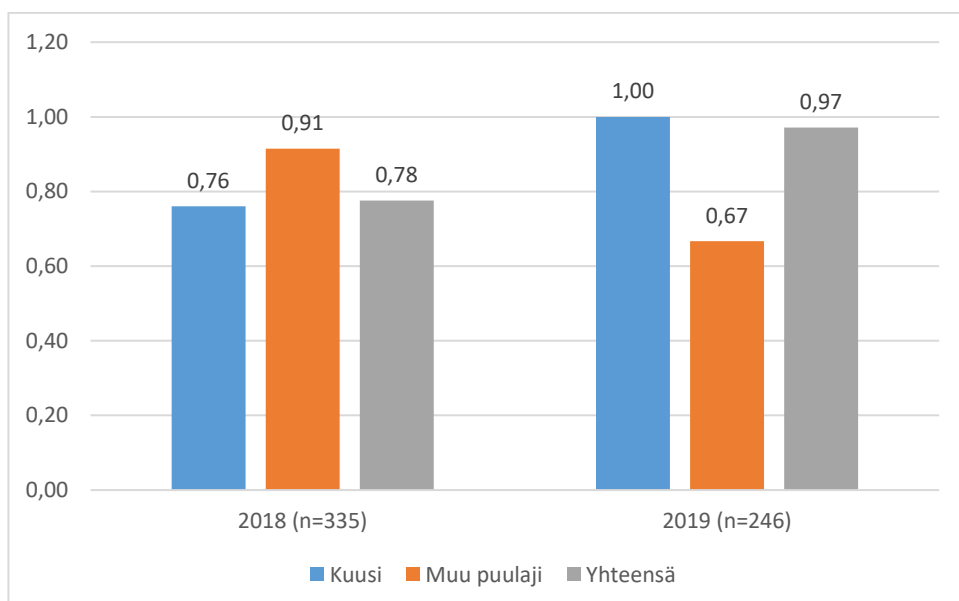
9.3 Puiden tunnistaminen ja puulajitulkinta

Puiden löytymiseen vaikutti kuvan laadun lisäksi puun rinnankorkeusläpimitta siten, että metsikössä suhteellisesti pienemmät puut katosivat kuvilta enemmän kuin suuret puut. Kuviossa 7 esitetään, kuinka läpimitta vaikutti puiden havaitsemiseen mallien välillä. Malli 2018 löysi kaikista koealoilla mitatuista puista 63 %, kun taas malli 2019 löysi 71 %. Pienet puut havaittiin heikoiten. Molemmat mallit havaitsivat alle kolmanneksen läpimitaltaan 15 - 20 cm:n puista (2018: 30 %, 2019: 29 %). Paras havainnointi puiden osalta tapahtui läpimittaluokassa 31 - 40 cm uudemman mallin kohdalla, jossa puista löytyi peräti 95 %.




Kuvio 7. Mallien havaitsemat puut rinnankorkeuslähimittaan mukaan, kaikki puulajit.

Puulajitunnistuksen osalta mallissa havaittiin tulosten perusteella paranemista. Vuoden 2018 mallissa kaikkien mallin löytämien puiden (n=335) puista tunnisti lajin mukaan oikein 78 % asteikolla kuusi-muu puulaji. Malli 2019 tunnisti oikein jo 97 % löydetyistä puista (n=246). Kuvio 8 voidaan havaita, että kaikki maastossa mitatut kuuset on mallin 2019 puulajitunnistuksessa luokiteltu oikein kuusiksi. Muiden puulajien osalta tunnistaminen oli jopa heikompaa kuin edellisessä mallissa. Tuloksia tulkittaessa tulee huomioida, että valtaosa tutkimusaineistosta oli kuusia, ja muiden puulajien osuus oli varsin pieni.



Kuvio 8. Puulajien oikein tunnistaminen, mallin tunnistamat puut (recall).

Kun otetaan huomioon kaikki tutkimusaineiston puut, joista siis noin kolmannes jäi mallien löytämättä, laskee mallin luotettavuus selvästi. Mallin 2018 oikeellisuus on vain 49 %, eli samaan tulokseen voisi päästä kolikkoa heittämällä. Mallin 2019 oikeellisuus puulajien tunnistamisessa on 69 % (kuvio 9).



Kuvio 9. Puulajien oikein tunnistaminen, kaikki maastossa mitatut puut (recall).

9.4 Terveyslukittelu

Puiden terveyslukittelu tehtiin kuusilla asteikolla terve-sairas-kuollut. Maastossa heikentyneeksi ja sairaaksi määritellyt puut luettiin analyysissä kuuluvan joukkoon "sairas". Luokassa "sairas" puiden väliset erot terveydessä olivat suuria maastossa tehtyjen havaintojen perusteella.

Tuloksien analysoinnissa käytettiin ristiintaulukointia (taulukko 1), josta laskettiin terveyslukitusten recall- ja precision-tunnukset luokakohtaisesti sekä Cohenin kapian arvo.


Taulukko 1. Molempien mallien terveystuokitusten ristiintaulukoinnit ja kappa-arvot.

2018 mallin terveystuokittelu						
Terveys	Terve	Sairas	Kuollut	yhteensä	recall	presicion
Terve	104	46	1	151	69 %	93 %
Sairas	8	37	9	54	69 %	44 %
Kuollut		1	22	23	96 %	69 %
yhteensä	112	84	32	228	71 %	71 %
			kappa	0,50		

2019 mallin terveystuokittelu						
Terveys	Terve	Sairas	Kuollut	yhteensä	recall	presicion
Terve	165	3		168	98 %	88 %
Sairas	23	19	5	47	40 %	86 %
Kuollut			10	10	100 %	67 %
yhteensä	188	22	15	225	86 %	86 %
			kappa	0,61		

Mallin 2018 Cohenin kappan arvoksi tuli 0,50. Kappan arvon ollessa välillä 0,41-0,60 yksimielisyyden voidaan olevan keskinkertainen. Mallissa 2019 kappan arvo nousi 0,61:een, jolloin yksimielisyys nousee Cohenin kappan -arvon voimakkuusasteikolla huomattavaksi.

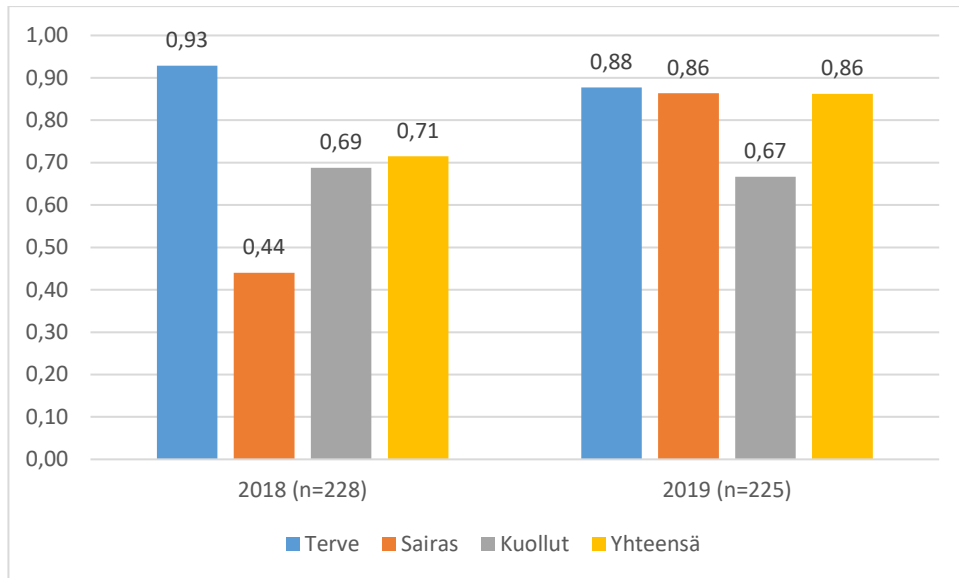
Tulosten analysoinnissa tutkittiin, kuinka hyvin terveys luokiteltiin samaksi miten se oli maastossa luokiteltu. Malli 2018 luokitteli 71 % havaitsemistaan kuusista terveydentilan mukaan samaksi kuin maastossa oli luokiteltu. Mallissa 2019 vastaava luku oli 86 %. Terveystuokkien välillä oli eroja, miten mallit tunnistivat terveydet oikein tai väärin. Paras tulos saatiin molempien mallien kohdalla luokassa ”kuollut”, jossa 2018 vuoden malli luokitteli 96 % kuolleista puista kuolleiksi, ja vuoden 2019 malli tunnisti kaikki kuolleet puut oikein. 2018 vuoden malli luokitteli 69 % terveistä ja sairaista puista oikein. Malli 2019 tunnisti hyvin kuolleet ja terveen puut, mutta sairaiden puitten luokittelussa oikein meni vain 40 %. Kuviossa 10 esitetään molempien mallien terveystuokittelun tulokset.



Kuvio 10. Oikein tulkitut terveydet, mallin tunnistamat kuuset (recall).


Mallin 2019 tuloksen heikkeneminen luokassa "sairas" on merkittävä. Tulosten perusteella uudempi laskentamalli tulkitsee puut sairaiksi, jos sen latvuksessa näkyy ilmakuvasa selvää heikentymistä. Vähemmän sairaas puu, esimerkiksi rungosta pihkoittunut, tulkitaan mallin mukaan terveeksi. Kun tarkastellaan mallin antamien tulosten täsmällisyyttä (precision), on tulokset paremmat.

Kuviossa 11 esitetään molempien mallien tulokset täsmällisyyttä tarkasteltaessa. Siitä havaitaan, että mallin 2019 tekemässä terveysluokassa "sairas" 86 % puista oli oikeastikin maastossa sairaita. Malliin 2018 verrattuna parannusta on tullut nimenomaan sairaiden puiden täsmällisyydessä peräti 42 prosenttiyksikköä. Terveiden puiden täsmällisyys on heikentynyt hieman mallista 2018 malliin 2019 verrattuna. Kuolleiden puiden määrä oli pieni aineistossa, ja siinä muutamankin puun virhetulkinta tekee täsmällisyydestä heikon.

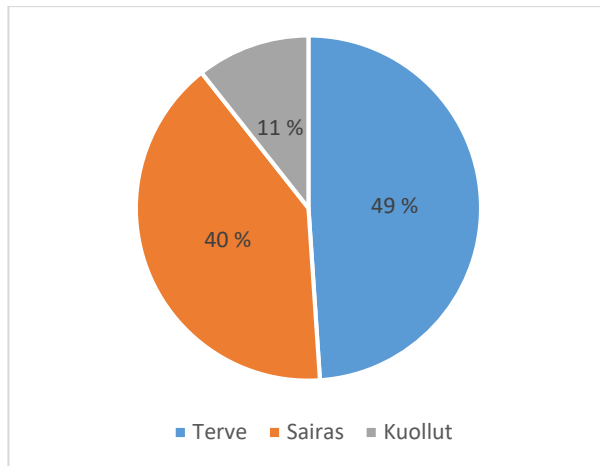


Kuvio 11. Terveyslukittelu, kuinka suuri osa mallin tekemistä terveystulkinnoista on maastossa tulkittu samoin (precision).

Kuviossa 12 esitetään mallin 2018 maastossa sairaiksi luokiteltujen puiden jakautuminen mallin terveyslukittelussa. Siinä luokittelussa virheitä on sattunut molempiin suuntiin lähes yhtä paljon, eli sairaita puita on luokiteltu terveiksi ja kuolleiksi. Maastossa sairaiksi luokitelluista kuusista luokiteltiin mallin 2018 mukaan 68 % sairaiksi, 17 % kuolleiksi ja 15 % terveiksi. Kuviossa 13 vastaava esitys mallin 2019 maastossa sairaiksi luokitelluista kuusista. Suurin osa sairaista puista on luokiteltu terveiksi. Maastossa sairaiksi todetuista kuusista luokiteltiin mallin 2019 mukaan 40 % sairaiksi, 49 % terveiksi ja 11 % kuolleiksi.




Kuvio 12. Vuoden 2018 mallin luokittelu, maastossa sairas (n=54).




Kuvio 13. Vuoden 2019 mallin luokittelu, maastossa sairast (n=47).

Tässäkin tulosten luotettavuudesta saatiin parempia tuloksia, kun tarkasteltiin mallin tekemän luokittelun täsmällisyyttä. Esimerkiksi malli 2019 luokitteli 22 kuusta sairaiksi. Näistä 19 oli maastossa todellisuudessaakin sairaita ja 3 terveitä (kuvio 14). Tästä voidaan päätellä, että malli 2019 on varovainen tulkitsemaan puuta sairaiksi, joka on tärkeä havainto mallin jatkokehitystä varten.




Kuvio 14. Vuoden 2019 mallin luokittelu, mallin mukaan sairaat (n=22).

Terveiden puiden osalta tulokset olivat molemmilla malleilla paremmat. Vuoden 2018 mallin maastossa terveiksi havaituista puista (yhteensä 151) 46 luokiteltiin väärin sairaaksi ja 1 väärin kuolleeksi (kuvio 15). Vuoden 2019 malli luokitteli terveistä puista (168) vain 3 väärin sairaaksi (kuvio 16).




Kuvio 15. Vuoden 2018 mallin luokittelu, maastossa terve (n=151).




Kuvio 16. Vuoden 2019 mallin luokittelu, maastossa terve (n=168).

Kuolleet puut tunnistettiin molemmissa malleissa hyvin. Mallissa 2018 yksi kuollut puu luokiteltiin väärin sairaaksi (kuvio 17), ja vuoden 2019 mallissa ei tullut lainkaan virheitä (kuvio 18).



Kuvio 17. Vuoden 2018 mallin luokittelu, maastossa kuollut (n=23).



Kuvio 18. Vuoden 2019 mallin luokittelu, maastossa kuollut (n=10).

9.5 Tulosten tarkastelu

Mallin opetuksen myötä tulokset paranivat puiden havaitsemisen, puulajitunnistuksen sekä terveyden tilan luokittelun osalta. Uudemmassa mallissa puiden löytäminen ja puuksi tunnistaminen parani 63 %:sta 71 %:iin. Puiden havaitsemisen onnistumiseen vaikutti suuresti puun rinnankorkeusläpimitta siten, että metsiköiden pienimmät puut jäivät molemmilla malleilla eniten näkemättä. Ilmakuvien tarkastelu silmämääräisestikin tuki tätä havaintoa. Pienempien kuusien latvat jäivät helposti isompien puiden latvuksen alle piiloon, erityisesti jos lehtipuusto oli kuvi-

olla runsasta. Tuloksista voi päätellä, että puiden havaitseminen on sitä parempaa, mitä tasakokoisempaa puusto on ja mitä vähemmän sekapuustoa, erityisesti isoja haapoja, esiintyy.

Tuloksissa syntyi selkeää heikkenemistä, kun verrattiin maastossa sairaiksi luokiteltuja kuusia mallin antamiin terveyslukitteluihin. Peräti 60 % maastossa sairaista kuusista luokiteltiin väärin mallin 2019 mukaan: suurin osa luokiteltiin terveiksi. Toisaalta kun tarkasteltiin mallin tekemistä, "sairas"-luokituksen saamista puista todellisia maastossa tehtyjä terveyslukituksia, tulosten täsmällisyys parani selvästi. Mallin 2019 mukaan sairaista puista 86 % oli todellisuudessaakin sairaita ja vain 14 % terveitä. Lisäksi Cohenin kappan arvo parani vuoden 2018 mallin arvosta 0,50:stä mallin 2019 arvoon 0,61. Sattuman merkitys tulosten oikeellisuudessa siis pieneni.

Vastaavia havaintoja oli myös Roope Näsin diplomityössä (2014), jossa sairaiden puiden oikeinluokitusprosentti oli parhaimmillaan 64 % ja Cohenin kappan arvo kyseisessä algoritmissa 0,47. Näsin tutkimuksessa käytettiin FPI-kameraa, jossa tutkittavia aallonpituuskanavia oli 41 kpl 550 - 880 nm:n väliltä.

Tässä tutkimuksessa terveyslukittelussa oikeinluokitusprosentti oli kokonaisuudessaan 71 % mallin 2018 tuloksissa ja 86 % mallin 2019 tuloksissa. Terve-kuollut -asteikolla kokonaistulosten oikeinluokitusprosentit olivat 95 % (malli 2018) ja 98 % (malli 2019). Näsin ym. (2018) tutkimuksessa, missä tutkittiin kirjanpainajan iskemiä kuusia hyperspektrikameralla, kolmen luokan terveyslukittelussa paras kokonaistarkkuus oli 76 %. Kahden luokan tarkastelussa, terve-kuollut, Näsin ym. tutkimuksessa oikeellisuus oli 90 %. Tulokset tukevat siis toisiaan, että hyper- tai multispektrikameran avulla kuusien terveyttä voidaan kartoittaa.

10 Pohdinta

10.1 Johtopäätökset

Päivitetty malli, eli vuoden 2019 malli, on varovainen arvioidessaan puita terveiksi, ja vain selvät sairastumiset tulevat luokitelluksi oikein. Tämä johtaa siihen, että varhaisessa vaiheessa sairastunut puu ei nouse tulkinnoissa esille. Toisaalta jos puu luokitellaan mallissa sairaaksi tai kuolleeksi, voidaan luottaa näiden arvioiden todennäköisesti menevän oikein. Tällöin puita ei luokitella turhaan sairaiksi, eli ns. turhia hälytyksiä metsän terveyden heikkenemisestä ei tehdä. On kuitenkin hyvä muistaa, että ohjelman tavoitteena on löytää altistuneet ja varhaisessa vaiheessa heikentyneet puut mahdollisimman aikaisin, jolloin hakkuilla pystytään estämään kirjanpainajapopulaation kasvu ja puuston arvon heikkeneminen kohteella.

Näsin (2014) mukaan terveiden ja sairaiden puiden spektrit eroavat toisistaan vain vähän, jolloin niiden luokittelun luotettavuus on heikempi kuin kuolleiden puiden luokittelussa. Näsi myös toteaa, että vaikka sairastuneiden puiden luokittelussa on vielä parannettavaa, voidaan terveystulkinnoista koostetuista tuhokartoista nähdä nopeasti kohteet, joissa kirjanpainaja aiheuttaa merkittävän riskin ympäröivän metsän terveydelle. Näille kohteille voi esimerkiksi kohdentaa hakkuita siten, että poistetaan vain vahingoittuneet ja sairastuneet puut. Tämä näkökulma huomioon ottaen terveystulkitusta voidaan harkita jo näillä tuloksilla. Mallin antamia terveystuloksia tulee osata tulkita oikein.

Puiden löytyminen ja havaitseminen oli toinen selkeä osa-alue, jossa on vielä parannettavaa. Mallin 2019 tuloksissa 71 % koealojen puista löytyi ja tunnistettiin puuksi. Lähes kolmannes puista oli siis kadonnut. Suurin osa näistä kadonneista puista oli rinnankorkeuslähimitaltaan metsän keskiläpimittaa ja valtapuustoa pienempiä. Metsän terveydentilan arvioimiseen nämä pienempien puiden puuttuminen ei välttämättä aiheuta suurta virhettä, mutta metsän puustotunnusten arvioimisessa virhe näkynee selvemmin. Jos tulevaisuudessa ohjelmaa halutaan käyttää metsän terveyden kartoituksen lisäksi esimerkiksi metsäsuunnitelman

päivittämiseen, on pohdittava, onko alempien latvuserrosten havainnointi tarpeellista. Tärkeintä on kuitenkin sekä metsän terveyden kartoituksessa sekä puuston inventoinnissa havaita ja mitata kohteella oleva valtapuusto oikein.

10.2 Jatkokehitystarpeet

Työn tavoitteena oli selvittää, onko ohjelma riittävän tarkka käyttöönottoa varten. Tulokset paranivat opetusaineiston lisäämisen myötä ja sattuman osuus pieneni. Tämän työn pohjalta voidaan suunnitella, mitä osa-alueita olisi hyvä jatkokehittää. Tulosten perusteella ainakin vanhojen ja järeiden kuusikoiden terveydentilaa voidaan tämän ohjelman avulla arvioida. Jatkokehitystarpeita on niin tulosten tarkkuuden lisäämisen suhteen kuin myös puiden löytymisen paranemiseen. Puiden havainnointiin liittyen olisi kiinnostavaa tutkia puiden sijoittumista toisiinsa nähden, jolloin pystyttäisiin päättelemään metsän tilarakenteen vaikutusta tulosten luotettavuuteen.

Terveydentilan varhaisista muutoksista kaivataan lisää opetusaineistoa, johon sisältyisi tarkempi tieto heikentymisen visuaalisista nähtävistä ensioireista. Jos mallin on tarkoitus osata tunnistaa varhaisen vaiheen sairastunut puu, on terveyslukuportaita syytä muuttaa neliportaiseksi. Silloin vältettäisiin tilanne, että luokan "sairas" sisällä puiden terveysvaihtelut suhteessa toisiinsa on liian suuret. Todennäköisesti malli oppii helpommin tunnistamaan tietyn luokan, kun kaikki siihen kuuluvat puut ovat mahdollisimman samankaltaisia.

Lentojen suorittamisessa ja kuvien latauksessa havaittiin myös haasteita. Kuvauksen onnistumiseen vaikutti voimakkaasti sää, joten suurien alojen kuvaaminen keliolosuhteiden salliessa on haastavaa. Kuvien laadun takaamiseksi lentoasetukset tuli säätää siten, että lentovauhti oli mahdollisimman hidas ja kuvien päällekkäisyys mahdollisimman suuri. Tämä johti siihen, että akut kuluivat nopeasti ja niitä tuli vaihtaa isojen alueiden kartoituksessa useasti kesken lennon. Tulevaisuudessa onkin hyvä pohtia, millaista lentokalustoa käytettäessä hyöty on suurin. Isompi ja vakaampi droni voisi pystyä tuottamaan hyvälaatuista kuvama-

teriaalia suuremmalta alueelta ja kovemmalla tuulella, mutta silti aurinko-olosuhteet rajoittavat kuvien onnistumista. Kuvausten suorittaminen pelkästään aurinkoisella tai pilvisellä säällä auringon ollessa korkeimmillaan on vaatimus, joka aiheuttaa ajankäytössä resurssivajetta. On hyvä pohtia myös, saadaanko lentokorkeutta muuttamalla parempi laatuksia ilmakuvia. Korkealta kuvattuna kohteen pikselikoko kasvaa, mutta yksittäisessä kuvassa reunavaikutuksen vääristävä osuus pienenee. Lain mukaan droonia voi lennättää korkeintaan 150 metrissä.

Tässä tutkimuksessa käytettiin droonia ja siihen yhdistettyä erillistä multispektrikameraa. Ilmakuvissa näkyi mm. vinossa olevia puita. Näitä laatuerojen syytä voidaan tutkia, jos tarkastellaan multispektrikameran ottamia yksittäisiä kuvia kohteilta. Yksittäisistä kuvista voisi todeta, onko siinä ollut virhettä vai onko virhe syntynyt myöhemmin mosakoinnissa. Erillisen kameran tuoma lisäpaino muutti droonin painopistettä, jolloin tuulen vaikutus droonin tasapainoon kasvoi. Jos kuvan ottamishetkellä drooni on ollut vinossa, niin kameran kuva ei ole voinut kohdistui kohtisuoraan maata kohti. Mahdollisesti tällainen ilmiö voi olla heikkolaatuisten ilmakuvien taustalla. Lisäksi navakka tuuli saattoi aiheuttaa sen, että puiden latvat heiluivat ja ne näyttivät liian erilaisilta stereokuvapareissa.

Kuvien latauksessa Stora Enson drooni-palveluun ilmeni haasteita kuvien ison määrän vuoksi, mutta ongelmat ovat varmasti korjattavissa mm. suurempien palvelimien avulla.

10.3 Luotettavuus

Tutkimuksen aineiston koon vuoksi tulosten tarkastelussa on hyvä huomioida kulloinkin oleva otoksen koko. Aineisto sisälsi eniten terveitä kuusia, ja niiden osalta tulosten luotettavuutta voidaan pitää hyvänä. Mallin 2019 tuloksia vertailtaessa aineiston koko väheni lähes puolella, koska osaa puista oli käytetty kyseisen mallin opetuksessa. Tällöin valmiiksi jo pienet havaintoryhmät, esimerkiksi kuolleet kuuset, jäivät entistäkin pienemmiksi aineistoiksi. Tämä johti siihen, että yksittäisenkin virhetulkinta luokittelussa johti prosentuaalisesti suuriin eroihin.

Maastomittauksissa puun terveys arvioitiin silmämääräisesti, jolloin kyseessä ei ollut tarkasti mitattavissa oleva arvo. Tässä apuna käytettiin siksi Luonnonvarakeskuksen tutkijaa Tiina Yliojaa sekä tutkimusassistenttia Leena Aarniota. Jatkossa vastaavaa tutkimusta tehtäessä olisi hyvä tarkemmin määritellä eri terveyslukien rajat, jolloin terveyslukittelu olisi tarkempi.

Tutkimuksessa käytetyt kohteet olivat sellaisia, joista on havaittu aiempina vuosina sekä vuonna 2019 kirjanpainajia. Puiden heikentymiseen tai kuolemiseen voi kuitenkin olla muitakin selityksiä kuin kaarnakuoriaisten iskeytyminen, ja usein puiden kuoleminen on monen asian yhteissumma. Tulosten perusteella ei siis voida määrittää luotettavasti sairaiden puiden olevan kirjanpainajan iskemiä, vaan voidaan vain olettaa puun heikentyneen syystä tai toisesta. Kuitenkin kun ohjelmaa sovelletaan vanhoissa kuusikoissa, voidaan olettaa kirjanpainajien olevan yksi todennäköinen syy.

Tulevaisuudessa terveyslukitteluohjelman tavoite on pystyä havaitsemaan vasta äskettäin heikentyneet yksilöt. Tähän mennessä mallia on opetettu aineistolla, jossa on käytetty vain vähän maastossa varhaisen heikentymisen ilmentäviä puita. Suurin osa mallin opetusaineistosta on puita, joiden terveyslukittelu on tehty ilmakuvasta pääteltävän terveydentilan perusteella. Tämä johtaa siihen, että malli myös tunnistaa paremmin ns. selvästi sairaat yksilöt ja tulkitsee vähemmän sairaat, latvastaan vielä terveen näköiset, puut terveiksi. Laadukkaan referenssiaineiston saaminen on avainasemassa ohjelman kehityksessä ja mallien laskentakaavojen koodaamisessa tulevaisuudessa.

Tutkimuksen kohteina olevien metsätilojen omistajat ovat antaneet luvan metsiensä tutkimuskäyttöön. Kuvista ei voi tunnistaa yksittäisiä ihmisiä.

Lähteet

- Dji. Phantom 4 pro. <https://www.dji.com/fi/phantom-4-pro>. 17.9.2019.
- Holopainen, M. 2019. Metsien kaukokartoitus – digilatisaatiota, täsmämetsätloutta ja 4D-geoinformatiikkaa. Metsätieteen aikakauskirja. 2019.
- Hänninen, R., Katila, P. & Västilä, S. 2013. Megatrendit muuttavat Suomen metsälää. Metsätieteen aikakauskirja. 4/2013.
- Junttila, S. 2019. Utilizing multispectral lidar in the detection of declined trees. Helsingin yliopisto.
- Kangas, A., Päivinen, R., Holopainen, M. & Maltamo, M. 2003. Metsän mittaus ja kartoitus. Silva Carelica 40. Joensuun yliopisto. Metsätieteellinen tiedekunta. Joensuu.
- Kankaanhuhta, V. 2014. MetINFO – Metsien terveys. Kirjanpainaja. Luonnonvarakeskus. http://www.metla.fi/metinfo/metsienterveys/lait_kansi/iptypo-n.htm. 24.7.2019.
- Karttunen, T. 2014. Kirjanpainajariskin arviointi ja hallinta Helsingin kaupungin taajamametsissä. Helsingin yliopisto. Pro gradu -tutkielma.
- Korvenranta, M. 2019. Kehityspäällikkö. Stora Enso Metsä. Haastattelu 3.10.2019.
- Kotala, J. 2019. Nurmikasvustojen havainnointi miehittämättömään ilmaalukseseen kiinnitettävällä multispektrikameralla. Helsingin yliopisto. Pro gradu -tutkielma.
- Laki metsätuhojen torjunnasta 1087/2013.
- Luonnonvarakeskus. 2015. Valtakunnan metsien inventointi (VMI). <http://www.metla.fi/ohjelma/vmi/info.htm>. 30.8.2019.
- Luonnonvarakeskus. 2016. Ilmastonmuutoksen vaikutus metsien vieraslaji-, tuho- ja tautiriskeihin. <https://www.luke.fi/tietoa-luonnonvaroista/metsa/metsat-ja-ilmastonmuutos/ilmastonmuutoksen-vaikutus-metsien-vieraslaji-tuho-ja-tautiriskeihin/>. 12.1.2020.
- Micasense. RedEdge-mx. <https://www.micasense.com/rededge-mx>. 2.8.2019.
- Näsi, R. 2014. Metsien hyönteistuhojen kartoitus käyttäen hyperspektrisiä ilmakuvia. Aalto-yliopisto. Diplomityö.
- Näsi, R., Honkavaara, E., Blomqvist, M., Lyytikäinen-Saarenmaa, P., Hakala, T., Viljanen, N., Kantola, T. & Holopainen, M. 2018. Remote sensing of bark beetle damage in urban forest at individual tree level using a novel hyperspectral camera from UAV and aircraft. Finnish Geospatial Research Institute.
- Pukkala, T. 1985. Metsän kaukokartoituksen perusteet. Silva Carelica 4. Joensuun yliopisto. Metsätieteellinen tiedekunta. Joensuu.
- Saaranen-Kauppinen, A. & Puusniekka, A. 2006. KvaliMOTV - Menetelmäopetuksen tietovaranto. <https://www.fsd.uta.fi/menetelmaopetus/>. 12.7.2019.
- Siren, T. 2008. Yksimielisyyden mittaamisen tilastolliset menetelmät. Tampereen yliopisto. Pro gradu -tutkielma.
- Trafi. 2018. Kauko-ohjatun ilma-aluksen ja lennokin käyttäminen ilmailuun. https://arkisto.trafi.fi/file-bank/a/1543326521/514c2766eb6f8413b2b0d71032cb4337/32598-OPS_M1-32_2018_fi.pdf. 8.9.2019.
- Uitto, M. 2017. Fotogrammetrian ja 3D-skannauksen hyödyntäminen 3D-mallinnuksessa. Lapin ammattikorkeakoulu. Opinnäytetyö.

- Ullakko, M. 2015. Nykyaikainen ilmakuvaus arkkitehdin työvälineenä. Aalto yliopisto. Diplomityö.
- Viiri, H., Viitanen, J., Mutanen, A. & Leppänen, J. 2019. Metsätuhot vaikuttavat Euroopan puumarkkinoihin – Suomessa vaikutukset toistaiseksi vähäisiä. Metsätieteen aikakauskirja 2019-10200
- Tuominen, S. 2015. Miehitettävät lentolaitteet (UAV) luonnonvarojen hallinnassa. Teoksessa Tuominen, S., Balazs, A., Saari, H., Pölönen, I., Sarkeala, J. & Viitala, R. (toim.). Metsätieteen aikakauskirja. Luke, 277 - 279.
- Uotila, A., Kasanen, R. & Heliövaara, K. 2015. Metsätuhot. Metsäkustannus: Latvia.