



Aalto-yliopisto
Insinöörیتieteiden
korkeakoulu

Metsien hyönteistuhojen kartoitus käyttäen hyperspektrisiä ilmakuvia

Aalto-yliopiston insinöörیتieteiden korkeakoulun
maankäyttötieteiden laitoksella tehty diplomityö

Espoo, marraskuu 2014

Tekniikan kandidaatti Roope Näsi

Valvoja: Professori Henrik Haggrén
Ohjaaja: TKT Eija Honkavaara

Tekijä Roope Näsi

Työn nimi Metsien hyönteistuhojen kartoitus käyttäen hyperspektrisiä ilmakuvia

Koulutusohjelma Geomatiikka

Pääaine Fotogrammetria ja kaukokartoitus**Professuurikoodi** Maa-57

Työn valvoja Professori Henrik Haggrén

Työn ohjaaja TkT Eija Honkavaara

Päivämäärä 10.11.2014**Sivumäärä** 61**Kieli** suomi

Tiivistelmä

Hyönteiset aiheuttavat metsätaloudelle merkittäviä taloudellisia tappioita. Hyönteistuhot ovat lisääntyneet viime aikoina myös Suomessa ilmastonmuutoksen vaikutuksesta. Erityisesti kaarna-kuoriaisiin kuuluva, kuusia tappava, kirjanpainaja on runsastunut lämpimien kesien seurauksena. Kirjanpainajien iskemien puiden tunnistaminen on tärkeää, jotta voidaan aloittaa toimet sen leviämisen estämiseksi. Tässä työssä tutkittiin, miten kirjanpainajatuhoja voidaan kartoittaa uudella, Suomessa kehitetyllä Fabry-Perot –interferometriin (FPI) perustuvalla, useita aallonpituusalueita mittavalla, hyperspektrikameralla, joka voidaan pienen kokonsa ja painonsa ansiosta sijoittaa lähes mille tahansa lentoalustalle. Lisäksi FPI-kamera kerää kokonaisia kuvamatriiseja, jolloin stereoskooppiset mittaukset ja näin ollen tiheiden 3D-pistepilvien luominen on mahdollista, toisin kuin aiemmin käytetyissä vain yhden pikselin tai rivin keräävissä hyperspektrikameroissa.

Tutkimusta varten kirjanpainajatuhoalueita kuvattiin Lahden kaupungin alueella pienlentokoneesta FPI- ja järjestelmäkameralla. Kuvatulta alueelta oli kerätty maastokoealoja, joiden alueilla olleista kuusista oli kerätty tietoja siitä, miten kirjanpainaja on niihin vaikuttanut. Vertaamalla näitä maastohavaintoja ja FPI-kameran tuottamaa spektriaineistoa oli tarkoitus selvittää, onko kirjanpainajatuhojen kartoittaminen FPI-kameran avulla mahdollista. Työssä selvitettiin myös, miten hyönteistuhoja on aiemmin kaukokartoitettu.

Kerätyistä kaukokartoitusaineistoista muodostettiin digitaaliset pintamallit sekä hyperspektraalit kuvamosaiikit. Näiden avulla saatiin muodostettua tuho kartat, jossa jokainen tutkimusalueen yksittäinen puu oli luokiteltu joko lehtipuuksi, terveeksi kuuseksi, sairastuneeksi kuuseksi tai kuolleeksi kuuseksi. Tämä tehtiin laskemalla jokaiselle tutkimusalueen puulle spektri ja luokittelemalla puut ohjatun luokittelun avulla siten, että luokittelijan opetukseen käytettiin maastokoealojen puita. Luokittelu tehtiin usealla eri algoritmilla. Tässä tapauksessa parhaat tulokset saatiin Spectral Correlation Mapper -algoritmin avulla, jolloin lehtipuut saatiin luokiteltu 96 %:n tarkkuudella oikeaan luokkaan, terveille kuusilla tämä prosentti oli 55, sairastuneille 64 ja kuolleilla kuusilla 81. Luokittelua vaikeutti se, että terveen ja sairastuneen kuusen spektrit eroavat vain vähän toisistaan. Saatujen tulosten perusteella FPI-kamera on lupaava vaihtoehto kirjanpainajatuhojen kartoitukseen.

Avainsanat Hyönteistuhot, kirjanpainaja, FPI-kamera, hyperspektriaineistot, radiometria, fotogrammetria, kaukokartoitus

Author Roope Näsi

Title of thesis Mapping of forest insect damage using hyperspectral aerial images

Degree programme Degree Programme in Geomatics

Major Photogrammetry and Remote Sensing**Code of professorship** Maa-57

Thesis supervisor Professor Henrik Haggrén

Thesis advisor D.Sc. (Tech.) Eija Honkavaara

Date 10.11.2014**Number of pages** 61**Language** Finnish

Abstract

Insects cause significant economic losses in forestry worldwide. Insect damage has also increased recently in Finnish forests due to the impact of climate change. In particular the population of the European spruce bark beetle has increased as a result of the warm summers and resulted in losses of millions of euros. It is important to identify trees to which they have attacked in order to initiate operations to prevent their spread. The objective of this study was to investigate how the damages by bark beetles can be mapped by using a new miniaturized hyperspectral camera that is based on Fabry-Perot Interferometer (FPI). The camera has developed in Finland and can be operated from almost any type of aerial vehicles. Furthermore, the FPI camera collects frame-format images enabling stereoscopic measurements. This provides a possibility for generation of dense point clouds and digital surface models; this is not possible with the conventional expensive hyperspectral instruments based on whiskbroom or pushbroom scanning.

For the empirical investigation, remote sensing data over areas of damages by bark beetles were collected in Lahti, Finland by the FPI spectral camera and commercial off-the-shelf SLR camera Nikon 3DX from a small manned aeroplane platform Cessna Cardinal RG. Field reference measurements were carried out in 30 field sample plots of size of 16 m by 16 m to identify impacts of bark beetles in every spruce. By comparing the field observations and spectral data from the FPI camera, we investigated if it is possible to identify damages by bark beetles using the FPI camera. Furthermore, a literature review was carried out to find out which remote sensing techniques have been used in the past to detect and map damages by insect pests in forests.

The collected remote sensing data were used to produce digital surface models and hyperspectral image mosaics. These allowed us to make damage maps, where every tree in the research area was classified as a broadleaf tree or healthy, infected or dead spruce. This was performed by training several different supervised classifiers using spectral features of trees in the field sampling plots. The best results were achieved by using the Spectral correlation mapper (SCM); the classification accuracy of broadleaf trees was 96 %, healthy spruces 55 %, infected spruces 64 % and dead spruces 81 %. It was challenging to classify healthy and infected spruces because their spectral features differed only slightly from each other. The results indicated that the FPI spectral camera is a potential alternative for the identification of damages by bark beetles. It was concluded that the novel light-weight, low-cost remote sensing technology enables new possibilities for the early identification of insect damages, in comparison to conventional technologies with heavy and expensive instrumentation.

Keywords Insect damage, European spruce bark beetle, FPI camera, hyperspectral data, radiometry, photogrammetry, remote sensing

Alkusanat

Haluan kiittää muutamia henkilöitä, jotka ovat edesauttaneet tämän työn valmistumista. Ensinnäkin kiitos osastonjohtaja, prof. Juha Hyypälle, joka tarjosi minulle mahdollisuutta tehdä diplomityö Geodeettisella laitoksella ja TkT Eija Honkavaaralle, joka tarjosi tätä MMEA –tutkimusohjelmaan liittyvää aihetta diplomityökseni. Eija toimi myös työni ohjaajana, joka kärsivällisesti, innostuneesti ja aktiivisesti ohjasi minua koko työn ajan. Ilman Eijaa ja hänen kehittelemiään menetelmiä tätä työtä ei olisi ollut mahdollista tehdä.

Kiitan myös tämän työn valvojaa, prof. Henrik Haggrenia, hyvistä neuvoista diplomityön viimeistelyssä. Haluan kiittää myös Lauri Markelinia, Teemu Hakalaa, Kimmo Nurmista, Paula Litkeyä ja monia muita kaukokartoituksen ja fotogrammetrian osaston työntekijöitä, jotka ovat aina pyydettäessä auttaneet minua työn eri vaiheissa. Kiitos myös kaikille laitoksen työntekijöille siitä, että ovat ottaneet minut osaksi työyhteisöään. Olennaisena osana tässä ovat olleet laitoksen tarjoamat virkistysmahdollisuudet, kuten suunnistuksen firmaliiga ja sulkapallon pelaaminen, joihin olen aktiivisesti osallistunut. Tärkeitä ovat olleet myös keskustelut kohtalotovereiden, eli yhtä aikaa diplomityötä kaukokartoituksen ja fotogrammetrian osastolla tehneiden, kanssa. Kiitos siis Saija Simolalle, Mika Kekäläiselle ja Risto Kaijaluodolle kokemusten jakamisesta.

Kiitos myös tämän projektin yhteistyökumppaneille eli Lentokuva Vallakselle, VTT:lle ja Helsingin Yliopiston metsätieteiden laitokselle. Yliopiston väestä haluan erityisesti kiittää Minna Lyytikäistä, Päivi Lyytikäinen-Saarenmaata ja Markus Holopaista, jotka ovat tarjonneet asiantuntemustaan tämän työn hyväksi.

Lopuksi haluan kiittää perhettäni ja ystäviäni, jotka ovat kannustaneet minua koko opiskelujeni ajan.

Sisältö

1	Johdanto.....	1
1.1	Tutkimuksen tausta ja tavoitteet.....	1
1.2	Tutkimusmenetelmät.....	2
1.3	Rajaus ja rakenne.....	2
2	Metsien hyönteistuhojen kaukokartoitus.....	4
2.1	Kirjanpainaja ja sen aiheuttamat tuhot.....	4
2.2	Hyperspektrikuva.....	5
2.3	FPI-kamera.....	6
2.4	Kaukokartoitus.....	7
2.4.1	Vihreän kasvillisuuden reflektanssiominaisuudet.....	7
2.4.2	Kasvillisuusindeksit.....	9
2.4.3	Spektriaineiston luokittelu.....	10
2.5	Kaukokartoituksen käyttö hyönteistuhojen kartoituksessa.....	12
3	Aineisto.....	15
3.1	Kuvaukset.....	15
3.2	Maastokoealat.....	19
4	Menetelmät.....	20
4.1	FPI-kuvien prosessointi.....	20
4.1.1	Radiometrian korjaus laboriokolibroinnilla.....	20
4.1.2	Spektraalisen vääristymän korjaus.....	20
4.1.3	Kanavasovitus.....	21
4.1.4	Orientointien selvittäminen ja pintamallin laskenta.....	22
4.1.5	Ortokuvablokin radiometrinen korjaus.....	23
4.2	Yksittäisten puiden tunnistaminen.....	25
4.3	Testipuiden spektrien laskeminen.....	26
4.4	Puiden luokittelu terveyslukkiin ja luokittelun arviointi.....	26
5	Tulokset.....	28
5.1	Kuvien laatu.....	28
5.2	FPI-kuvien esiprosessointi.....	28
5.2.1	Radiometrian korjaus laboriokolibroinnilla.....	28
5.2.2	Spektraalisen vääristymän korjaus.....	29

5.2.3	Kanavasovitus	30
5.3	Orientointien ratkaisu	31
5.4	Pintamallit	34
5.5	Reflektanssimosaikin laskenta	36
5.5.1	Absoluuttisen radiometrisen kalibroinnin määrittäminen	37
5.5.2	Suhteellisen radiometrisen kalibroinnin määrittäminen	39
5.6	Koalojen puiden spektrit ja niiden vastaavuus maastohavaintoihin	43
5.7	Puiden luokittelu ja tuhokartat	48
6	Johtopäätökset.....	53
	Lähteet.....	56

Lyhenteet

BRDF	Bidirectional reflectance distribution function, kaksisuuntainen heijastusfunktio
BRF	Bidirectional reflectance factor, kaksisuuntainen heijastustekijä
CCD	Charge-Coupled Device
CHM	Canopy height model, latvusmalli
CIR	Color-infrared, väärävärikuva
CMOS	Complementary Metal-Oxide-Silicon
DLT	Direct linear transformation, suora lineaarinen muunnos
DN	Digital number, kuvan harmaasävyarvo
FOV	Field of view, näkökentän laajuus
FPI	Fabry-Perrot –interferometri
FPI-kamera	Fabry-Perrot –interferometriin perustuva spektrikamera
FWHM	Full Width at Half Maximum, puoliarvoveveys
GA	Genetic algorithm
GPS	Global Positioning System
GSD	Ground sample distance, näytteenottotiheys, pikselikoko maastossa
K1, K2	Radiaalisen piirtovirheen parametrit
MML	Maanmittauslaitos
NDVI	Normalized Difference Vegetation Index, normalisoitu kasvillisuusindeksi
NGATE	Next Generation Automatic Terrain Extraction
PPA	Principal Point of Autocollimation, autokollimoitu pääpiste
RGB-kuva	Red, green, blue; kolmen värin avulla esitetty värikuva
RMSE	Root-mean-square error, keskineliövirheen neliöjuuri
RVI	Ratio Vegetation Index, kasvillisuusindeksi
SAM	Spectral Angle Mapper, luokittelualgoritmi
SCM	Spectral Correlation Mapper, luokittelualgoritmi
SIFT	Scale-invariant feature transform

SNR	Signal-to-noise ratio, signaalikohinasuhde
SVM	Supervised support vector machine
UAV	Unmanned Aerial Vehicle, miehittämätön lennokka
UTC	Coordinated Universal Time, koordinoitu yleisaika

1 Johdanto

1.1 Tutkimuksen tausta ja tavoitteet

Ilmastonmuutoksen myötä hyönteisten aiheuttamat metsätuhot lisääntyvät myös Suomen metsissä. Erityisesti kuusiin iskevä, kaarnakuoriaisiin kuuluva, kirjanpainaja on viime vuosina runsastunut eteläisessä Suomessa niin paljon, että sen aiheuttamat taloudelliset menetykset ovat olleet jopa miljoonia euroja, ja lämpimien kesien ja myrskytuulten jatkuessa tuhojen on arvioitu entisestään laajenevan. Ilmaston lämpenemisen lisäksi ilmastonmuutoksen vaikutuksesta lisääntyneet, puita kaatavat, myrskyt ovat myös vaikuttamassa kirjanpainajatuhojen leviämiseen, sillä kirjanpainajat iskevät ensi sijassa jo kaatuneisiin tai heikentyneihin kuusiin. Tämä nähtiin Ruotsissa, jossa suurten myrskytuhojen jälkeen kirjanpainajakannat kasvoivat niin suuriksi, että ne pystyivät tappamaan suurilta alueilta myös täysin terveitä kuusia aiheuttaen huomattavasti suuremmat taloudelliset vahingot mitä Suomessa on tähän mennessä nähty.

Kirjanpainajan aiheuttamat tuhoalueet on tärkeä löytää, jotta voidaan aloittaa toimet tuhojen leviämisen estämiseksi. Erityisen tärkeää olisi tunnistaa sellaiset puut, joihin kirjanpainaja on jo iskenyt mutta, jotka eivät ole vielä kuolleet, sillä tällaisten puiden poistaminen vähentää metsän kirjanpainajien määrää. Kuusissa voi nähdä kirjanpainajien aiheuttamia merkkejä maastossa liikuttaessa mutta varsinkin alussa merkkien huomaaminen voi olla hankalaa ja aikaa vievää. Tämän takia tuhojen automaattinen kartoittaminen ilmasta käsin olisi kiinnostavaa ja tässä työssä tutkitaankin kirjanpainajatuhojen kaukokartoitusta.

Suomessa VTT on kehittänyt uuden Fabry-Perot -interferometriin (FPI) perustuvan spektrikameran, jolla voidaan kerätä aineistoa useiden kymmenien aallonpituuskaistojen alueella (Saari, ym. 2011). Etuna aiemmin kehitettyihin spektrikameroihin tässä kehitetyssä kamerassa on sen keveys, mikä mahdollistaa kuvaukset useilta pieniltäkin kuvausalueilta, kuten lennokeista (UAV, Unmanned Aerial Vehicle). Lisäksi kamera kuvaa kokonaisia kuvamatriiseja kerrallaan, jolloin on mahdollista tehdä myös stereoskooppisia mittauksia. Tällöin kuvista on mahdollista tuottaa pintamalleja ja tiheitä 3D-pistepilviä kehittyneillä fotogrammetrisilla menetelmillä (mm. Markelin ym. 2014). Nämä ovat uusia ominaisuuksia hyperspektrikameroille. Tällaisen kameran uskotaan soveltuva hyvin ympäristönmuutoseurantaan ja sitä onkin käytetty jo menestyksekkäästi mm. biomassan estimointiin tarkkuusviljelyssä (Honkavaara ym. 2013).

Tässä työssä on tavoitteena selvittää, miten tätä kameraa voidaan käyttää metsäsovelluksissa, ja nimenomaan kirjanpainajatuhojen kartoittamisessa. Työn tavoitteena on myös selvittää, miten hyönteistuhonja on aiemmin kaukokartoitettu. Työn tavoitteet voidaan tiivistää seuraaviin vastausta vailla oleviin tutkimuskysymyksiin:

1. Miten FPI-kameran keräämää spektristä aineistoa voidaan käyttää kirjanpainajatuhojen kartoittamiseen?

- a. Mitä vaiheita kuvien käsittelyyn liittyy ennen kuin niitä voidaan käyttää tuhokartoitukseen?
- b. Miten ja millä tarkkuudella voidaan luoda puukohtaisia tuhokarttoja?

2. Miten hyönteistuoja on aiemmin kaukokartoitettu?

1.2 Tutkimusmenetelmät

Jotta ensimmäiseen tutkimuskysymykseen olisi mahdollista vastata, on FPI-kameralla kuvattu Lahden kaupungissa laajoja kirjanpainajatuhoalueita pienlentokoneella. Tuhoalueelta on myös kerätty maastosta koealoja, joilla sijainneilta kuusilta on kerätty tietoa siitä, miten kirjanpainaja on niihin vaikuttanut. Näitä maastohavaintoja ja FPI-kameran tuottamaa spektriaineistoa vertaamalla on mahdollista selvittää, onko kirjanpainajatuhojen kartoittaminen tällä aineistolla mahdollista. Tämän vaiheen tutkimusmenetelmänä on kvantitatiivinen tutkimus eli käyttää ongelman ratkaisemiseksi laskennallisia menetelmiä.

Toisen tutkimuskysymyksen ratkaisemiseksi käytetään tutkimusmenetelmänä kirjallisuustutkimusta. Myös ensimmäisen tutkimuskysymyksen ratkaisemisessa käytetään osittain hyväksi kirjallisuustutkimusta, etenkin kysymyksen 1. b ratkaisussa. Kirjallisuustutkimuksessa lähteinä käytetään pääasiassa tieteellisiä julkaisuja.

1.3 Rajaus ja rakenne

Tämän työn aiheena on fotogrammetria ja kaukokartoitus. Sen vuoksi tässä tutkimuksessa keskitytään erityisesti niihin liittyviin kysymyksiin, joita tässä tapauksessa ovat spektriaineistojen prosessointi geometrisesti ja radiometrisesti sekä näiden avulla tehtävä kirjanpainajatuhojen kaukokartoitus. Edellä mainittuihin suoraan liittymättömiä asioita, kuten FPI-kameran tarkkaa toimintaperiaatetta ja kirjanpainajien leviämistä ja muita biologiaan liittyviä asioita käsitellään vain lyhyesti.

Tähän tutkimukseen liittyvässä projektissa FPI-kameralla oli kuvattu koko tutkimusalue pienlentokoneella sekä pienempiä alueita myös miehittämättömällä lennokilla. Tämä työ rajataan koskemaan ainoastaan pienlentokoneesta kerättyä aineistoa. Lentokoneaineistoa oli kerätty Lahden kaupungissa kahdelta alueelta. Työn aikana tutkimusaluetta rajattiin vielä tarkimmin niin, että lopulliset kirjanpainajatuho-kartat tehtiin ainoastaan näistä kahdesta alueesta suuremmalle alueelle, jotta aineiston analysointiin käytettävä aika ei kasvaisi liian suureksi.

Luvussa 2 pyritään hakemaan kirjallisuustutkimuksen avulla toiseen tutkimuskysymykseen vastausta. Luku alkaa työhön liittyvien oleellisesti liittyvien asioiden, kuten kirjanpainajien ja FPI-kameran esittelyllä ja päättyy alalukuun siitä, miten hyönteistuoja on kaukokartoitettu aiemmin. Kolmannessa luvussa kuvaillaan tutkimuksessa käytössä ollut aineisto eli FPI-kameralla tehdyt kuvaukset ja maastossa kerätyt koalat. Luvussa 4 esitellään tutkimuksessa käytetyt ja kehitetyt menetelmät teoriassa ja seuraavassa eli viidennessä luvussa menetelmien avulla saadut tulokset. Luvussa 5 esitetään saatujen tulosten lisäksi myös

alustavaa tulosten analysointia. Lopulliset tulosten johtopäätökset on esitetty viimeisessä eli kuudennessa luvussa.

2 Metsien hyönteistuhojen kaukokartoitus

2.1 Kirjanpainaja ja sen aiheuttamat tuhot

Kirjanpainajat (*Ips typographus* L.) ovat 4,2-5,5 mm:n kokoisia kaarnakuoriaisia (Kuva 1). Kirjanpainajat aiheuttavat tuhoja lisääntyessään kuusten kuoren alla. Kirjanpainajien toukat syövät kuusen nilakerrokseen käytäviä, jolloin puun nestevirtaukset katkeavat ja puu alkaa vähitellen kuivua. Mikäli syömäkuviot yltävät koko rungon ympäri, puun veden saanti katkeaa kokonaan ja se lopulta kuolee. Kirjanpainajan iskemässä kuusessa alkaa tapahtua monia muutoksia, kuten latvuksen värin muuttuminen kellertäväksi ja lopulta ruskeaksi, kaarnan irtoaminen vähitellen sekä harsuuntuminen eli neulasten vähentyminen. Ensimmäisiä oireita kirjanpainajien iskeytymisestä puuhun ovat pihkavuodot, iskeymäaukot ja ruskea puru rungolla. Yleensä kirjanpainajat iskevät heikentyneisiin kuusiin, tuulentaatoihin tai metsään jääneisiin tukkeihin. Populaation kasvaessa ne voivat kuitenkin iskeä myös täysin terveisiin puihin. Mikäli asiaan ei puututa, tuhot voivat laajentua rintamana tai pesäkkeittäin jopa useiden vuosien ajan. Tämän takia kirjanpainajatuhojen aikainen havaitseminen on tärkeää laajojen tuhojen välttämiseksi. (Kärvemo ja Scroeder 2010, Wermelinger 2004)




Kuva 1 Vasemmalla kirjanpainajan syömäkuviota kuusessa. Kuvattu Lahdessa kesällä 2014, © Roope Näsi. Oikealla kirjanpainaja-kaarnakuoriainen, © Minna Lyytikäinen

Kirjanpainajatuhojen torjumiseksi on säädetty myös 20.12.2013 voimaan tullut metsätuholaki, joka mm. velvoittaa poistamaan hakatun kuorellisen kuusipuutavaran metsistä määrärajoissa (Finlex 2013). Kirjanpainajat ja muut kaarnakuoriaiset ovat aiheuttaneet maailmanlaajuisesti paljon metsätuhoja ja ne ovat pahimpia metsien hyönteistuhojen aiheuttajista Euroopassa (mm. Christiansen ja Bakke, 1988). Pohjois-Amerikassa kaarnakuoriaiset ovat aiheuttaneet myös erittäin laajoja tuhoja, jopa kymmenien miljoonien hehtaarien alueella (Bentz et. al. 2010). Ruotsissa kirjanpainajat ovat tuhonneet viime vuosien aikana useita miljoonia kuutioita kuusta siellä riehuneiden myrskyjen tarjotessa sopivaa lahoppuuta (Kärvemo ja Scroeder 2010). Suomessakin tuhot ovat lisääntyneet viime vuosien lämpimänä kesinä, erityisesti Etelä- ja Kaakkois-Suomessa. Kirjanpainajatuhojen todennäköisyyden arvioidaankin kasvavan ilmaston lämmitessä (Jönsson ym. 2009). Myös kuivuuden on todettu olevan eräs tekijä, joka vaikuttaa kirjanpainajatuhojen leviämiseen (Faccoli, 2009).

Suomessa Metsäkeskus (2014) on arvioinut että vuonna 2013 kirjanpainaja on aiheuttanut kahden miljoonan euron taloudelliset vahingot mutta tulevina vuosina ne saattavat kasvaa moninkertaiseksi.

2.2 Hyperspektrikuva


Sähkömagneettisen kentän aaltoliikettä sanotaan sähkömagneettiseksi säteilyksi, joka jaetaan säteilyn aallonpituuden perusteella eri osa-alueisiin, kuten näkyvään valoon ja infrapunasäteilyyn. Kuva 2 on esitetty sähkömagneettisen säteilyn spektri, jossa nähdään muun muassa, että näkyvä valo on vain pieni osa koko spektristä.



Kuva 2 Sähkömagneettinen spektri, jonka pienenä on myös näkyvän valon aallonpituudet (muokattu lähteestä Pölönen 2013)

Digitaalikuvaus perustuu siihen, että kameran kenno (useimmin CCD tai CMOS) tallentaa pikseleittäin siihen tulevan säteilyn sen intensiteetin mukaan. Esimerkiksi 8-bittisessä harmaasävykuvassa on 256 mahdollista arvoa, jossa 0 vastaa mustaa ja 255 valkoista arvoa. Jotta kuvasta saataisiin värillinen, voidaan yhden kennon tapauksessa käyttää suodinmatriisia, joka jakaa pikselit punaisen, vihreän ja sinisen alueelle. Tyypillisin tällainen suodinmatriisi on Bayer-matriisi, jossa joka toinen pikseli tallentaa vihreää, jolloin punaista ja sinistä tallentavia pikseleitä on vain joka neljäs. Tämän takia puuttuvat pikselit tietyllä kanavalla joudutaan kuitenkin interpoloimaan muista havaituista arvoista. On myös mahdollista ohjata kolme kanavaa suotimien kautta kolmelle eri kennolle tai käyttää kolmea eri kameraa, jolloin interpolointia ei tarvita.


Harmaasävykuvan voidaan sanoa olevan 1-ulotteinen kuvamatriisi ja RGB -värikuva onkin jo 3-ulotteinen kuvamatriisi. Hyperspektrikuvassa tallennettavia aallonpituusalueita kavennetaan mutta määrää kasvatetaan kymmeneen jopa sataan eri kanavaan. Näin muodostuvaa kuvaa voidaan kuvaila kuvakuutioksi (Kuva 3), jossa jokaisella pikselillä on arvo monella eri aallonpituusalueella.



Kuva 3 Hyperspektrinen kuvakuutio ja yhden pikselin spektri (muokattu lähteestä Pölönen ym. 2013)

2.3 FPI-kamera

VTT on kehittänyt Fabry-Perot'n interferometrin (FPI) ja RGB-kuvasensorin yhdistelmään perustuvaa kevyttä spektrikameraa jo muutaman vuoden ajan. Fabry-Perot'n interferometrin olennaisimpana osana on kaksi puoliläpäisevää, vastatusten olevaa, peiliä. Peiliparin läpäisee vain hyvin pieniä aallonpituusalueita, jotka ovat peilien välisen ilmaraon funktiona. Näin ollen vaihtamalla ilmarakoa saadaan kerättyä uusia aallonpituusalueita. Käytännöllä RGB-kuvasensoreja saadaan samanaikaisesti tallennettua jopa kolme kapeaa aallonpituuskaistaa. Interferometrin ja RGB-kuvasensorin välissä on lisäksi ali- ja ylipäästösuoittimet, joiden avulla suodatetaan tarpeettomat aallonpituusalueet pois (Kuva 4). Tällä tavoin saadaan spektritietoa jokaisesta kuvan pikselistä ilman interpolointia. Kaikkien kanavien (aallonpituusalueiden) valotus ei kuitenkaan tapahdu samanaikaisesti, joten sensorin ollessa liikkeessä kuvien kanavat eivät ole raakadatassa vielä päällekkäin. (Saari ym. 2011, Mäkyne ym. 2011)



Kuva 4 FPI-kameran rakenne kaaviokuvana (muokattu lähteestä Pölönen ym. 2013)

Geodeettisen laitoksen käytössä olevan FPI-kameran polttoväli on 10,9 mm ja aukkosuhde on alle 3. RGB-kuvasektorina on CMOSIS CMV4000, jonka koko on 2048*2048 pikseliä. Pikselikoko on 0,0055 mm. Käytännön sovelluksessa käytetään kuitenkin 2-binnausta virheiden vähentämiseksi. Tällöin neljää pikseliä (2*2) käsitellään kuin yhtä pikseliä, jolloin pikselin arvoksi saadaan näiden neljän pikselin keskiarvo. Lisäksi kaikki kennon pikseleitä eivät ole käytössä. Tämän takia kuvakoko on 1024*648 pikseliä ja pikselikoko on 0,011 mm. Käytettävään aallonpituusalueeseen voi vaikuttaa käyttämällä erilaisia suotimia ja valitsemalla mitä ilmarakoja käytetään. Tässä sovelluksessa käytettiin aallonpituuksia n. 500-900 nm:iin. Spektraalista erotuskykyä eli aallonpituusalueen leveyttä voidaan kuvata FWHM -arvolla (Full Width at Half Maximum, puoliarvoveveys), joka tarkoittaa sellaisten pisteiden välimatkaa funktion maksimiarvon vastakkaisilla puolilla, joissa funktio saa puolet maksimiarvostaan. FPI-kamerassa FWHM -arvo vaihtelee 10 ja 40 nm:n välillä riippuen suotimista ja käytettävästä ilmaraosta.

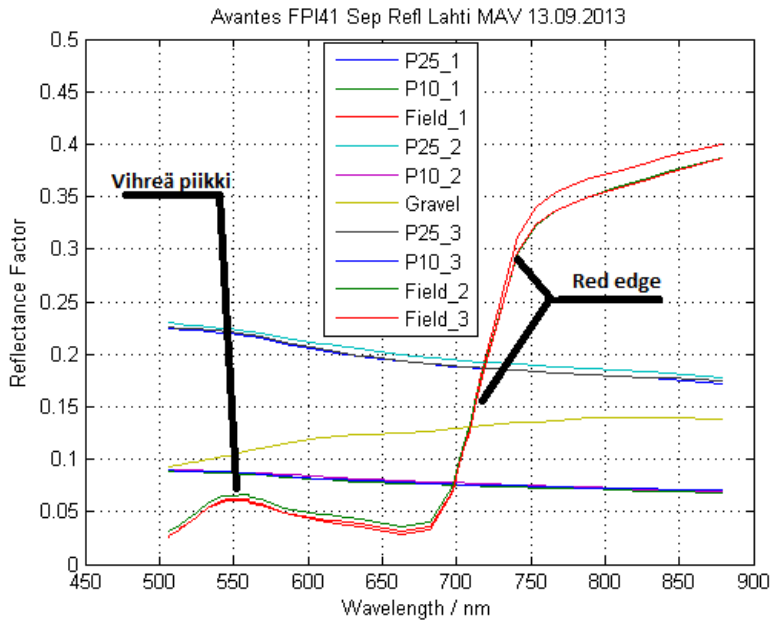
Oleennaista FPI-kamerassa on sen keveys. Laitteen paino on vain alle 700 g. Tämä luku sisältää itse kameran lisäksi muut lisälaitteet, kuten akut, paikannuslaitteen, kaapelit ja irradianssisensorit. Tämän ansiosta kuvauksia voidaan tehdä myös keveiltä lentoalustoilta, kuten UAV:sta (Unmanned Aerial Vehicle). Aiemmin käytössä olleet spektrikamerat ovat olleet liian painavia UAV:lle. Toisena oleellisena FPI-kameran etuna on se, että sillä voidaan kerätä aluemaisia kuvia, mikä mahdollistaa stereoskooppisen mittauksen. Useat aiemmin käytössä olleet laitteet ovat keränneet tietoa joko yksi pikseli tai rivi kerrallaan, jolloin stereoskooppiset mittaukset eivät ole olleet mahdollisia. (Saari ym. 2011, Honkavaara ym. 2013)

2.4 Kaukokartoitus

Kaukokartoitusta voidaan tehdä passiivisilla tai aktiivisilla instrumenteilla. Aktiivinen instrumentti lähettää kohteeseen säteilyä ja mittaa takaisin heijastuneen säteilyn (esim. tutka, laserkeilaus). Sen sijaan passiivinen instrumentti ei itse lähetä mitään säteilyä, vaan se ainoastaan mittaa kohteesta tulevaa säteilyä, joka on useissa tapauksissa heijastunutta auringonvaloa. Tässä tutkimuksessa on käytetty ainoastaan passiivisia instrumentteja.

2.4.1 Vihreän kasvillisuuden reflektanssiominaisuudet

Auringosta maahan saakka tuleva sähkömagneettinen säteily on suurelta osin aallonpituudeltaan 300 ja 2500 nm:n välissä eli se sisältää pääosin näkyvää valoa (400-700 nm) ja infrapunasäteilyä (700 nm-). Kun sähkömagneettinen säteily osuu kohteeseen se voi absorboitua, heijastua tai läpäistä kohteen. Eri kohteet reagoivat tähän säteilyyn eri tavoin ja kullekin kohteelle muodostuu niille ominainen heijastusspektri. Vihreille kasveille ominaista on se, että ne absorboivat lähes kaiken näkyvän valon yhteyttääkseen mutta heijastavat suuren osan säteilyn vaihtuessa näkyvästä valosta infrapunasäteilyksi. Tätä vihreän kasvillisuuden säteilyn jyrkkää nousua n. 700 nm:n kohdalla sanotaankin ”red edgeksi” (punainen reuna). Näkyvän valon alueella vihreille kasveille on ominaista myös n. 550 nm:n kohdalla oleva ”vihreä piikki”, minkä vuoksi ihminen kokeekin kasvien lehdet vihreinä (Kuva 5).




Kuva 5 Kuvasta nähdään kasvillisuuden spektrille ominaiset piirteet vihreä piikki ja red edge. Kuvassa on myös mm. soran spektri, joka poikkeaa huomattavasti kasvillisuuden spektristä. Mittaukset on tehty kenttäspektrometrillä Lahdessa pienlentokonekuvausten aikana 13.9.2013.

Tällaisia kullekin kohteelle yksilöllisiä ominaisspektrejä voidaan käyttää hyväksi erilaisten kohteiden tunnistuksessa. On kuitenkin huomattava, että mitattuun säteilyarvoon vaikuttavat muutkin seikat kuin kohteen heijastusominaisuudet. Näistä seikoista huomattava on väliaineen eli käytännössä ilmakehän vaikutus, sillä ilmakehä sirottaa ja absorboi säteilyä. Tarkkojen tulosten saamiseksi ilmakehän vaikutus on huomioitava tekemällä aineistolle radiometrinen korjaus. Muita sävyarvoihin vaikuttavia tekijöitä ovat mm. kohteen geometria ja mittausajankohta.

Digitaaliset kamerat mittaavat kameran kennolle tulevan säteilyn kirkkausarvoja ja samalla tallentaa kullekin pikselille kirkkautta vastaavan harmaasävyarvon (Digital number, DN). Kunkin pikselin kirkkauteen vaikuttaa itse kohteen kirkkauden lisäksi muun muassa aurin gon sijainti ja säteilyteho. Muun muassa tämän takia pelkän DN:n käyttö spektrien vertailussa ei ole mielekäästä. Sen sijaan voidaan käyttää reflektanssia eli heijastussuhdetta (ρ), joka kuvaa tietyllä aallonpituudella kohteesta lähteneen $E_r(\lambda)$ ja siihen saapuneen säteilyenergian $E_I(\lambda)$ suhdetta (kaava 1):

$$\rho_\lambda = \frac{E_r(\lambda)}{E_I(\lambda)} \quad (1)$$

joka voi saada arvoja 0:n ja 1:n väliltä. Reflektanssin laskemiseksi on määritelty kaksisuuntainen heijastusfunktio (BRDF, bidirectional reflectance distribution function). BRDF on sensorin ja valaistuslähteen mittausgeometrian parametrien (Kuva 6) sekä säteilyn aallonpituuden funktio. (Lillesand ym. 2008, s. 12-29).



Kuva 6 Mittausgeometria: θ_i ja ϕ_i ovat saapuvan säteilyn (irradianssi) sekä θ_r ja ϕ_r lähtevän säteilyn (radianssi) zenitti- ja atsimuuttikulmat (muokattu lähteestä Markelin 2013).

BRDF:ä ei voida mitata suoraan, joten on määritelty mitattava kaksisuuntainen heijastustekijä (BRF, bidirectional reflectance factor). BRF on kohteesta heijastuneen ja täysin häviöttömästä diffuusista pinnasta (= pinta, joka heijastaa saapuvan säteilyn yhtä suurena kaikkiin suuntiin eli Lambertin pinta) samoissa olosuhteissa heijastuneen säteilytehon suhde. BRF voi saada myös yli 1:n olevia arvoja.

2.4.2 Kasvillisuusindeksit

Erilaisia kasvillisuuden määrää ja laatua kuvaavia indeksejä on kehitetty kymmenittäin 1970-luvulta lähtien (Landsat-kuvien käyttöön tulo). Kasvillisuusindeksit hyödyntävät juuri kasvillisuuden ominaispektrien ominaisuuksiin eli muun muassa sitä, että lehdet heijastavat suurimman osan saamastaan lähi-infrasäteilyä mutta absorboivat suurimman osan punaisen alueen säteilyä yhteystämistä varten.

Treitz ym. (2010) jakavat kasvillisuusindeksit kahteen pääryhmään ja useampaan alaryhmään. Ensimmäisessä pääryhmässä ovat leveän kaistan indeksit (Broad-Band Indices), joissa kasvillisuusindeksejä johdetaan käyttämällä kokonaisten aallonpituusalueiden avulla, kuten käyttämällä punaista ja lähi-infrakanavaa..

Leveän kaistan (eli multispektraaliset) indeksit voivat perustua kanavien välisten suhteiden käyttämiseen. Näistä kaksi yleisesti käytettyä ja yksinkertaista indeksiä ovat Rouse ym. (1974) kehittämää. Tunnetuin on normalisoitu kasvillisuusindeksi (Normalized Difference Vegetation Index, NDVI), joka määritellään punaisen (Red) ja lähi-infrakanavan (Nir) reflektanssin avulla (kaava 2):

$$NDVI = \frac{\rho_{Nir} - \rho_{Red}}{\rho_{Nir} + \rho_{Red}} \quad (2)$$

Indeksi saa arvoja -1 ja +1 väliltä siten, että lähellä +1 ovat arvot kertovat runsaasta kasvillisuudesta ja päinvastoin.

Vielä edellä mainittuakin yksinkertaisempaa RVI:tä (Rouse ym. 1974) käytetään nopeaan kasvillisuusalueiden määrittämiseen. RVI (kaava 3) määritellään yksinkertaisesti lähi-infrakanavan ja punaisen kanavan suhteeksi:

$$RVI = \frac{\rho_{Nir}}{\rho_{Red}} \quad (3).$$

Myös muita kuin suhteeseen perustuvia leveän kaistan indeksejä on olemassa. Esimerkiksi etäisyyteen perustuva yksinkertainen kasvillisuusindeksi lasketaan punaisen ja lähi-infran alueen reflektanssien erotus. On myös kehitetty runsaasti erilaisia lineaarisia muunnoksia, erityisesti landsat-kuvien prosessointiin, joista useat ovat ns. Tasseled Cap -muunnoksia. (Treitz ym. 2010, s.17-23)

Toisen kasvillisuusindeksien pääryhmän muodostavat kapeiden kaistojen avulla lasketut indeksit, joita voidaan kutsua myös hyperspektrisiksi indekseiksi. Myös useat kapeiden kaistojen kasvillisuusindeksien kaavat perustuvat NDVI:hin mutta käyttävät siis vain hyvin kapeaa aallonpituusaluetta.

Yleistetyin näistä on Thenkabail ym. (2000) esittelemä optimaalinen kapean kaistan NDVI (kaava 4), jossa käydään kaikki mahdolliset kanavayhdistelmät läpi ja valitaan niistä se, joka korreloi parhaiten kiinnostuksen kohteena olevaan biofysikaliseen parametrin kanssa:

$$NDVI_{ij} = \frac{\rho_{Nir_j} - \rho_{Red_i}}{\rho_{Nir_j} + \rho_{Red_i}} \quad (4)$$

Koska hyperspektriaineistossa kanavia on paljon ja ne ovat lähes jatkuvia, voidaan indeksejä muodostaa myös differentiaalilaskennan avulla, esimerkiksi derivoimalla (red-edgeä) tai integroimalla koko infrapuna-alueen yli. (Treitz ym. 2010)

2.4.3 Spektriaineiston luokittelu

Kaukokartoituksessa on usein tavoitteena jakaa kiinnostuksen kohteena oleva alue tietyn teeman mukaisesti luokkiin, kuten maankäyttöluokkiin. Tässä luokittelussa kutsutussa menetelmässä käytetään hyväksi yleensä kuvilta saatavia piirteitä, joista yleisimpiä ovat eri kanavilta mitatut arvot. Tämän tehtävän automatisoimiseksi on kehitetty erilaisia luokittelualgoritmeja, jotka voidaan jakaa karkeasti kolmeen luokkaan: ohjattuun luokitteluun, ohjaamattomaan luokitteluun eli ryhmittelyyn sekä näiden yhdistelmään eli ohjattuun ryhmittelyyn. Erona näillä on se, että ohjaamattomassa luokittelussa ei välttämättä tarvita mitään ennakkotietoa itse kohteesta mutta ohjatussa luokittelussa kartoitettavasta alueesta on osattava rajata luokiteltavaksi haluttuja kohteita.

Ohjatussa luokittelussa tarvitaan jokaisesta kartoitettavasta luokasta ennakkotietoa sen piirteistä. Ennakkotieto voi olla kerättyä erityisiin spektrikirjastoihin tai ennakkotieto voidaan kerätä luokiteltavalta kuvalta osoittamalla siitä kullekin luokalle tyypillisiä alueita, joita kutsutaan opetusalueiksi. Ennakkotiedon keräämisen jälkeen tarvitaan algoritmi luokitteluun muuttamalla pikselit haluttuihin luokkiin. Seuraavassa kuvaillaan usein, ja tässäkin työssä, käytettäviä luokittelualgoritmeja yleisellä tasolla menemättä tarkempiin yksityiskohtiin.

Yksinkertainen luokittelualgoritmi on minimietäisyyden luokittelija, jossa lasketaan ensin opetusluokan keskiarvo tai mediaani jokaisella kanavalla ja saadaan näin jokaiselle luokalle keskivektori. Sen jälkeen lasketaan luokiteltavan pikselin ja jokaisen luokan keskivektorin euklidiset etäisyydet ja luokitellaan pikseli siihen luokkaan missä tämä etäisyys on lyhin. Minimietäisyyden luokittelualgoritmi on yksinkertainen ja nopeasti laskettava algoritmi, mutta sen suurin puute on se, että se ei hyödynnä ollenkaan opetusalueiden piirre-vektoreiden hajontaa. (Lillesand ym. 2008, s. 551)

Minimietäisyyden luokittelijan ohella pitkään käytetty luokittelualgoritmi on todennäköisyyslaskentaan perustuva suurimman uskottavuuden luokittelu, joka huomioi luokittelussaan myös opetusvektoreiden hajontaa huomioimalla opetusvektoreiden varianssin. Opetusvektoreiden avulla muodostetaan luokille todennäköisyyttä kuvaavat tiheysfunktio ja luokiteltava pikseli luokitellaan siihen luokkaan, jonka tiheysfunktio antaa suurimman todennäköisyyden kuulua tähän luokkaan. Suurimman uskottavuuden luokittelulla on saatu usein hyviä tuloksia mutta menetelmä vaatii sen, että opetusvektorit ovat erityisen laadukkaita eli että ne kattavat erityisen hyvin koko kuvaamansa luokan, jotta tiheysfunktioiden luominen onnistuu. (Lillesand ym. 2008, s. 554-557)

Spectral Angle Mapper (SAM) -algoritmi on kehitetty erityisesti hyperspektrisen datan luokitteluun. Sen ideana on, että jokainen spektri voidaan esittää vektorina moniulotteisessa avaruudessa, jossa ulottuvuuksia on yhtä paljon kuin kanavia. Vektorin pituuteen vaikuttaa valaistuksen määrä mutta vektorin suunnan pitäisi pysyä samoilla kohteilla jokseenkin samana. Tämän takia SAM-algoritmissa vertaillaankin vektoreiden välisiä kulmia ja pikseli luokitellaan siihen luokkaan, jossa opetusluokan vektorin ja luokitettavan vektorin välinen kulma on pienin (Lillesand ym. 2008, s. 612). Spectral Correlation Mapper (SCM) on samankaltainen kuin SAM mutta siinä vektorit normalisoidaan ennen kulmien laskemista vähentämällä spektrivektoreista kaikkien vektoreiden keskiarvo (De Carvalho ym. 2000).

Ohjaamattomassa luokittelussa ei ole ennalta määritelty opetusluokkia mutta luokkien lukumäärä täytyy jossain algoritmeissa määrittellä ennen laskentaa. Näin on mm. K-means -algoritmissa, jossa aineisto jaetaan ensin satunnaisesti K:hon luokkaan ja lasketaan näiden keskiarvo. Tämän jälkeen luokitellaan havainnot luokkaan, jonka keskiarvo on lähimpänä. Saaduista uusista luokista lasketaan taas keskiarvot ja luokitellaan havainnot uudelleen lähimpään luokkaan. Tätä toistetaan niin kauan, kunnes keskiarvot eivät enää muutu. ISODATA on K-means -luokittelun kaltainen luokittelija mutta siinä ei ole välttämätöntä antaa luokkien määrää etukäteen ja luokkia voidaan yhdistää tai jakaa kesken luokittelun. Ohjatussa ryhmittelyssä käytetään hyväksi sekä ohjaamatonta että ohjattua ryhmittelyä esimerkiksi siten, että ohjaamattomalla luokittelijalla muodostetaan ensin spektraalisesti samankaltaisia ryhmiä, joista perusteella valitaan opetusaineisto ohjattua luokittelua varten. (Lillesand ym. s. 569-574)

2.5 Kaukokartoituksen käyttö hyönteistuhojen kartoituksessa

Hyperspektraalista aineistoa on käytetty jonkin verran erilaisten hyönteistuhojen kartoituksessa. Taulukkoon 1 on kerätty eri tutkimuksia, joissa on tutkittu hyönteisten kasvillisuudelle aiheuttamien tuhojen kartoitusta. Tutkimuksista on kerätty tiedot hyönteisestä, kohde-tyypistä, tutkimuksessa käytetystä sensorista sekä tutkittavana olleen aallonpituusalueen laajuudesta. Lisäksi on kerätty niitä aallonpituuksia, jotka on tutkimuksessa todettu olleen mielenkiintoisimpia tai hyödyllisimpiä tuhojen kartoituksessa sekä kerrottu minkälaiseen menetelmätyyppiin, kuten regressioanalyysiin, tutkimus pohjautuu.

Taulukko 1 Tutkimuksia hyönteisten kasvillisuudelle aiheuttamien tuhojen kartoittamisesta. Mikäli hyönteisen tai menetelmälle ei ole löytynyt suomenkielistä nimeä, se on esitetty siten kuin alkuperäisessä julkaisussa.

Lähde	Hyönteinen	Kohde	Sensori	Tutkittu aallonpituusalue (nm)	Mielenkiintoimmat aallonpituusalueet (nm)	Menetelmä
Lausch ym.2013	Kaarna-kuoriaiset	kuusikot	Hymap	450-2480	450-890	Regressioanalyysi
Fassnacht et al. 2014	Kaarna-kuoriaiset	kuusikot	Hymap	450-2480	560, 680, 690, 1532, 1076	GA, SVM
Lawrence & Labus, 2003	Douglas-Fir Beetle	kuusikot	Hymap	450-2430		Regressioanalyysi (CART)
Prabha-kar ym. 2011	Leafhopper	puuvil-lapelto	FieldS-pec3	350-2500	691, 761, 1457	Regressioanalyysi
Stone ym. 2001	Kaikki hyönteiset	eukalyp-tus	Per-sonal Spec II	400-1000	550, 590-740	Regressioanalyysi
Fitzge-rald ym. 2004	Strawberry spider mite	puuvil-lapelto	Aviris	450-1000	550, 700	Spectral Mixture Analysis
Leckie ym. 2005	Jack pine budworm	metsät	MEIS	448-2200	667, 2200	Regressioanalyysi
Pontius ym. 2008	Saarnenja-losoukko	metsät	SPec-TIR	450-990	605, 760	Regressioanalyysi
Mirik ym. 2006	Greenbug	syys-vehnä	Ocean Optics S2000	340-1015	712, 719, 761, 908,	Regressioanalyysi
Cheng ym. 2010	Kaarna-kuoriaiset	metsät	FieldS-pec	350-2500	1318-1322, 950-1390, 1550-2370	Continuous wavelet analysis

Fassnacht ym. 2012	Kaarnakuoriat	kuusikot	Hymap	455-986	484, 529, 645, 705, 861, 939	SVM
Meigs ym. 2011	Kaarnakuoriat	metsät	Landsat TM	Kanavat 4 ja 7	4: 760-900, 7:2080-2350	Aikasarjat

Kaarnakuoriaten aiheuttamien tuhojen kartoitusta hyperspektraalista aineistoa on tehty Koillis-Saksassa Bavarian kansallispuiston alueella useita tutkimuksia. Lausch ym. (2013) tutkimuksessa tuhoalueita oli kuvattu Hymap-sensorilla, joka keräsi 125 kanavaa aallonpituusalueelta 450-2480 nm. He käyttivät aineiston analysoinnissa regressioon perustuvia menetelmiä ja kartoituksen kannalta mielenkiintoisimmat aallonpituusalueet löytyvät heidän mukaansa väliltä 450-890 nm. He myös huomasivat, että maastoresoluution pienentäminen 7 m:stä 4 m:iin parantaa luokittelutuloksia mainittavasti. (Lausch ym. 2013)

Fassnacht ym (2014) käyttivät samaa aineistoa kuin Laush ym. (2013) mutta analysoinnissa käytettiin erilaisia menetelmiä eli geneettistä algoritmia (genetic algorithm, GA) ja edistyneistä tukivektorikonetta (supervised support vector machine, SVM). Heidän tutkimuksensa mukaan tuhojen kartoituksessa mielenkiintoisia aallonpituusalueita löytyi ”vihreän piikin” ja ”red edgen” lisäksi lähi-infrapunan alueilta 1532 ja 1076 nm:n kohdalta.

Taulukkoon 1 kerätyt tutkimukset on tehty käyttämällä tuhojen kartoitukseen pääasiassa lentokoneista tehtyjä hyperspektrikuvauksia. Tämän lisäksi lukuisia hyperspektraalista dataa hyväksikäyttäviä tutkimuksia on tehty laboratoriossa analysoimalla esimerkiksi terveitä ja eri tavalla vahingoittuneita kasvinosia, kuten Qin ym (2011) tutkiessaan sitrushedelmiä. Myös satelliittikuvia on käytetty runsaasti tuhojen analysointiin. Taulukossa 1 on esitetty tästä esimerkkinä multispektraalisten Landsat-kuvien käyttö nimenomaan kaarnakuoriaten tuhojen kartoituksessa (Meigs ym. 2011). He käyttivät tutkimuksessaan multitemporaalista aineistoa eli analysoivat tuhojen etenemistä aikasarjojen avulla. Heidän mukaansa mielenkiintoisimmat Landsat-kanavat olivat 4 (760-900 nm) ja 7 (2080-2350 nm).

Kirjanpainajatuhoja on myös kartoitettu hyödyntämällä väärävärivuvia (CIR), jotka sisältävät punaisen, vihreän ja lähi-infrakanavan (Heurich ym. 2010). He tutkivat tuhoja myös samassa Bavarian kansallispuistossa ja heillä oli käytössään väärävärimosaiikit kahdelta peräkkäiseltä vuodelta. He luokittelivat kohdealueensa kuolleiden ja terveiden puiden alueisiin hyödyntämällä muun muassa NDVI:tä ja saivat luokittelutarkkuudeksi 91,5 %. He eivät kuitenkaan pitäneet väärävärivuvia parhaina mahdollisina aineistoina kirjanpainajia tappaneiden puiden kartoittamiseen. (Heurich ym. 2010)

Pohjois-Amerikassa kaarnakuoriaten kuusille aiheuttamia tuhoja kaukokartoituksen avulla ovat tutkineet mm. Meddens ym (2011). He käyttivät multispektraalista aineistoa, joka sisälsi kanavat siniselle, vihreälle, punaiselle sekä lähi-infralle. Heidän havaintojensa mukaan mm. kaarnakuoriaten sairastuttamien kuusien reflektanssi on suurempi näkyvän va-

lon alueella mutta pienempi lähi-infralla. He luokittelivat aineistonsa pikseleittäin ja ilmoittivat luokittelutarkkuuden olevan parhaimmillaan 90 %. (Meddens ym. 2011)

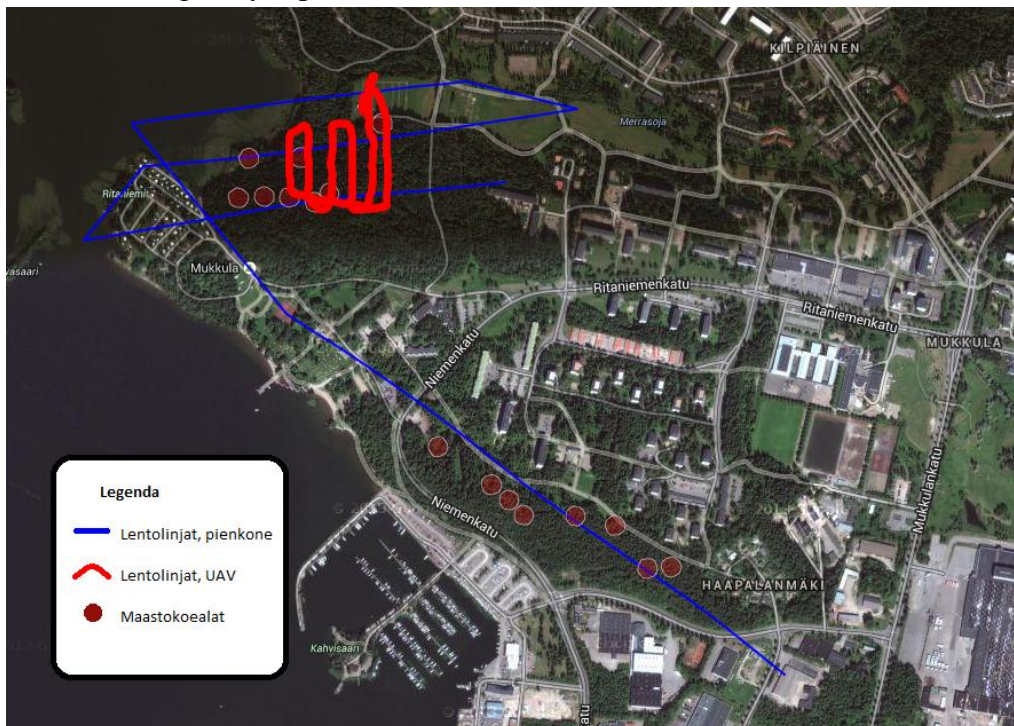
Hyönteistuhojen kartoitusta aktiivisilla kaukokartoitusinstrumenteilla, kuten laserkeilaimella, on myös tutkittu. Erityisesti havupuiden harsuuntuneisuuden kartoittamiseen laserkeilauksen on todettu soveltuvan hyvin. (Vastaranta ym. 2013, Kantola ym. 2013). Laserkeilauksesta ja väärävärικuvista saatavien piirteiden yhdistämistä on myös tutkittu harsuuntuneiden puiden kartoittamiseksi (Kantola ym. 2010).

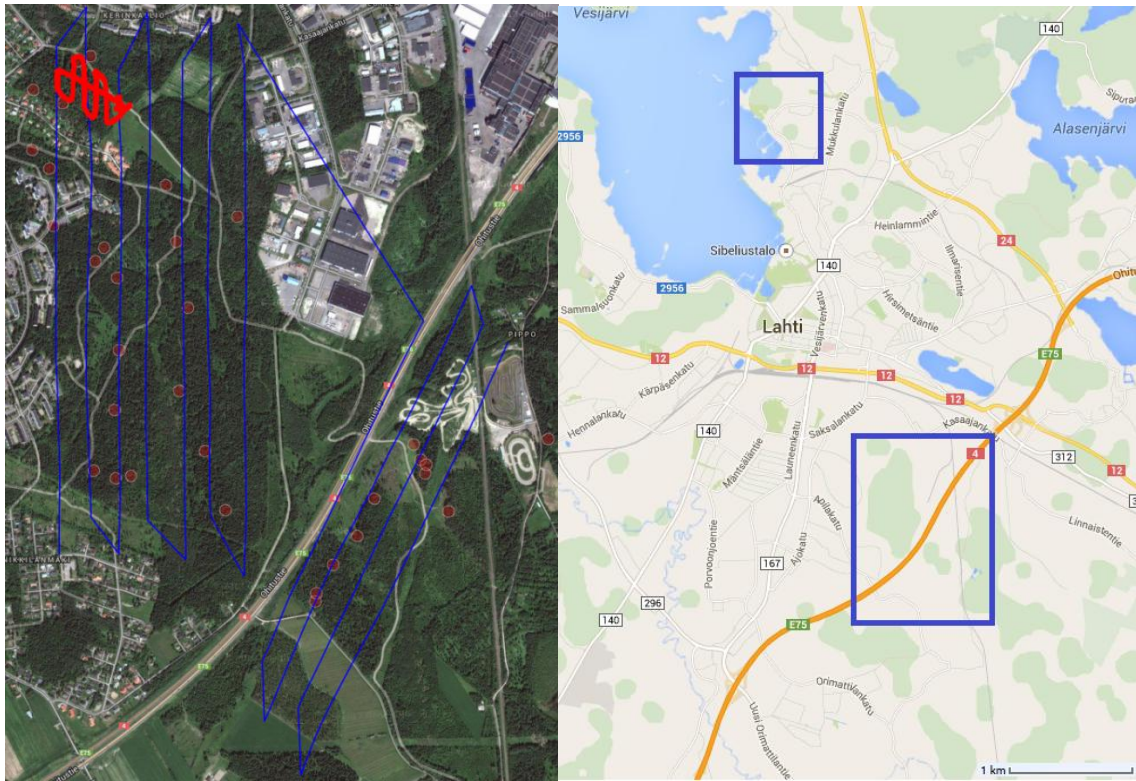
3 Aineisto

Tutkittava kirjanpainajatuhoalue sijaitsee Lahden kaupungin taajamametsissä, joissa kirjanpainajapopulaatiot alkoivat runsastua vuoden 2011 jälkeen. Lahden taajamametsät koostuvat yhteensä 5000 hehtaarista ja pääpuulajina on kuusi (*Picea abies* L. Karst.).

3.1 Kuvaukset

Kirjanpainajatuhoalueita kuvattiin pienlentokoneesta syksyllä 2013. Kuvaukset tehtiin sekä FPI-kameralla spektridatan keräämiseksi että RGB-kameralla tarkemman maanpinnan erotuskyvyn saamiseksi. Kuva 7 on merkitty pienkoneen ja myös projektia varten kuvattujen, mutta tässä työssä käsittelemättömien, miehittämättömien lennokkien (UAV) lentolinjat sekä Helsingin yliopiston metsätieteiden laitoksen maastossa keräämät koealat.





Kuva 7 Kirjanpainajatuhoalueilla Lahdessa tehdyt kuvaukset ja maastokoealojen sijainnit. Ylempänä pohjoisempi blokki ja alla vasemmalla eteläinen blokki sekä oikealla blokkien sijainti Lahden kaupungissa. (pohjakuva © Google, 2014).

Pienlentokoneesta kuvattiin koko tutkimusalue 13.9.2013. Kuvaukset suoritettiin Lentokuva Vallaksen Cessna Cardinal RG –koneella. Kyseisessä koneessa on vain yksi kuvausaukko, joten molempia kuvauksia ei voitu tehdä yhtä aikaa. Tämän takia lentojonot kuvattiin ensin Lentokuva Vallaksen omalla RGB-kameralla (Nikon D3x) ja tämän jälkeen vaihdettiin lennossa FPI-kameraan ja lennettiin samat lentolinjat uudelleen, tosin FPI-kuvaukseen lentokorkeutta nostettiin noin sadalla metrillä. Nikon D3x on kompaktikokoinen järjestelmäkamera, jossa CMOS-kennon koko on 6080*4044 pikseleissä ja 35,9*24,0 millimetreissä sekä kalibrointitodistuksen mukainen kameravakio 51,4128mm.

RGB-kuvaukset tehtiin n. 400 metrin korkeudelta, jolloin näytteenottotiheys (Ground Sample distance, GSD eli pikselikoko maastossa eli spatiaalinen resoluutio) saatiin n. 5 cm:iin. RGB-kuvauksessa lentokoneen nopeus oli keksimäärin 39 m/s ja FPI-kuvauksen aikana 35 m/s. FPI-kuvissa lentokorkeus siis nostettiin 500 metriin, jolloin GSD on n. 0,5 metriä. Kaikkien lennettyjen lentoblokkien aikaiset tiedot on esitetty Taulukko 2. Pohjoisemmassa blokissa oli kolme samansuuntaista lentolinjaa ja yksi erisuuntainen linja (Kuva 7). FPI-kuvauksessa nämä linjat peittivät toisensa, joten niitä käsiteltiin yhtenä blokkina (Pohjoinen, FPI) mutta RGB kuvauksessa näin ei ollut, joten linjat käsiteltiin eri blokkeina (Pohjoinen 1 RGB; Pohjoinen 2, RGB). Pienlentokoneen kuvausaukkoa ei ole suunniteltu FPI-kameran tapaiselle kameralle, vaan objektiivilla varustetuille järjestelmäkameroille. Lisäksi FPI-kamera on laajakulmaisempi (FOV 50, 37) kuin RGB-kamera (36, 26). Tämän takia FPI-kuville kuvautui reunoille tummat aukonreunat (Kuva 8).

Taulukko 2 Blokkien lennonaikaiset tiedot: GSD, keskimääräinen lentokorkeus, lentolinjojen sivu- ja pituuspeittoprosentit, auringon sijainti (ks. Kuva 6) ja kuvausaika.

Blokki	Kamera	GSD (m)	Lentokorkeus (m)	Peittoprosentit		Auringonsijainti		Kuvausaika (UTC+3)
				Sivu	Pituus	Zen (°)	Ats (°)	
Pohjoinen 1	RGB	0,05	400	60 %	75 %	57,3	182,5	13:20-13:23
Pohjoinen 2	RGB	0,05	400	0 %	75 %	57,3	183,4	13:24-13:25
Etelä	RGB	0,05	400	60 %	75 %	57,4	186,4	13:27-13:45
Pohjoinen	FPI	0,5	500	75 %	70 %	57,7	191,4	13:48-13:55
Etelä	FPI	0,5	500	75 %	70 %	58,2	195,8	13:57-14:14



Kuva 8 Vasemmalla esimerkkikuva lähi-infran (829,2 nm) alueelta. Oikealla kuvauksessa käytetty Cessna Cardinal RG –pienkone kuvattuna heti kuvausten jälkeen (© Teemu Hakala).

Kameran liike kuvakuution välillä kuvaonottovälin on 180 pikseliä eli 90 m. Kuvakuution sisällä kuvat valottuvat 0,75 sekunnin välein eli liike on 5 pikseliä ja koko kuvakuution aikana liike on 115 pikseliä.

Kuvauksissa kerättiin myös GPS-tietoja ulkoisten orientointien sijaintitietojen likiarvojen saamiseksi. RGB-kuvat otettiin yhden sekunnin välein ja lentokoneen GPS tallensi paikansa myös samoin tasasekunnein. FPI-kuvauksessa tarkin GPS-data oli kerätty myös sekunnin välein. Kuvien valotusajat kuitenkin vaihtelivat 2,6 ja 3,2 sekunnin välillä ja lisäksi FPI-kameran toiminnasta johtuen lähes jokaiselle kanavalle valotushetki oli eri. Tiedossa oli kuitenkin kunkin kanavan valotushetki kuvakuution alusta, joten kaikille kanaville saatiin interpoloitua likimääräiset projektiokeskusten sijainnit.

Kuvauksen aikana myös mitattiin maasta käsin irradianssimittauksia Avantes-kenttäspektrometrillä. Tästä datasta saattaa olla hyötyä blokin radiometrisessä korjauksessa. FPI-kamerassa on myös pienet laajakaistaiset irradianssisensorit, joiden avulla irradianssia saadaan mitattua kuvanottopaikoista. Näissä kuvauksissa tätä ei kuitenkaan ollut mahdollista tehdä, sillä irradianssisensoreita ei ollut mahdollista kiinnittää lentokoneessa siten, että mittausdata olisi ollut luotettavaa.

Lisäksi maastoon oli levitetty referenssikohteita, joiden heijastusta mitattiin kenttäspektrometrillä (Kuva 9). Sää oli kuvausten aikana puolipilvinen, joten kuvilta on jonkin verran havaittavissa pilvien varjoja (Kuva 9).




Kuva 9 Maastoon levitettyjä referenssi kohteita, pilviä lennon aikana ja niiden aiheuttamia varjoja kuvilla. (Vasen ja keskimäinen kuva © Lauri Markelin)

Maastossa ei ollut signaloitu tai mitattu mitään maastotukipisteitä blokkitasoituksen avuksi. Alueelta oli kuitenkin saatavissa Maanmittauslaitoksen (MML) avoimia aineistoja, kuten ortokuvia ja laserkeilausdataa, joiden avulla luonnollisia maastotukipisteitä oli mahdollista saada.

FPI-kameraan on mahdollista valita mitattavien aallonpituuksien sarja. Kasvillisuussovelluksissa erityisen mielenkiintoisia ovat vihreän piikin (550 nm) ja lähi-infran (700- nm) alueet. Tämän takia mitattavaksi valittiin 41 kanavaa 505 ja 880 nm:n väliltä (Taulukko 3, Kuva 10), joiden spektraalisesta resoluutiota kuvaavien FWHM-arvot vahtelevat 12 ja 23 nm:n välillä.

Taulukko 3 FPI-kameralla kerättyjen alkuperäisten 41 kanavan keskiaallonpituudet ja puoliarvoveydet (FWHM)

Alkuperäinen data
Aallonpituus (nm): 505.90, 506.50, 512.60, 514.00, 517.60, 521.40, 524.60, 533.70, 534.60, 540.20, 543.10, 546.60, 560.00, 560.10, 560.30, 561.20, 568.50, 584.10, 607.40, 613.30, 619.50, 634.90, 640.80, 662.20, 681.90, 697.30, 701.50, 707.80, 707.80, 713.70, 713.70, 717.80, 719.60, 741.40, 753.80, 767.00, 789.40, 807.90, 829.20, 842.00, 879.10
Puoliarvoveveys (nm): 12.82, 14.85, 14.61, 19.08, 17.11, 21.71, 30.15, 14.94, 22.18, 17.07, 17.51, 21.92, 17.22, 21.64, 14.81, 32.32, 15.66, 22.99, 30.92, 28.89, 30.15, 16.93, 27.75, 16.82, 19.80, 16.01, 27.36, 25.73, 15.40, 26.14, 19.34, 20.01, 27.10, 19.72, 26.69, 30.50, 27.90, 26.98, 28.97, 20.43, 20.75



Kuva 10 Spektrivaste alkuperäisille 41 kanavalle.

3.2 Maastokoealat

Kuvausten lisäksi tarvittiin tietoja maastosta, joiden avulla voidaan löytää yhteys spektrianneiston ja puiden terveystietojen välille. Tätä tarkoitusta varten käytettiin referenssinä Helsingin yliopiston metsätieteiden laitoksen tutkijoiden keräämiä tietoja alueen kirjainpainaipopulaatiosta ja puustotuhoista. Tietoja kerättiin koealoilta, joita on yhteensä 49 kpl ja niiden koot ovat 16*16 m. Pohjoisemman blokin alueella sijaitsee 16 ja eteläisemmällä alueella 33 koealaa. Kolme eteläisen alueen koealoista oli kuitenkin hieman kuvausalueen ulkopuolella (Kuva 7), joten tältä alueelta oli käytössä 30 koealaa. Vuonna 2013 koealojen puista mitattiin pituus ja rinnankorkeusläpimitta. Koealat paikannettiin GPS-laitteella (Trimble) ja merkittiin maastoon (Kuva 11). Koealojen puiden paikat määritettiin suunnan ja etäisyyden avulla keskipisteestä. Jokaisesta koealan kuusesta kerättiin lisäksi terveyteen liittyviä tietoja, joita kutsutaan tässä terveysparametreiksi. Latvuksen väri arvioitiin neljään luokkaan normaalista vihreästä kellertävän ja ruskean kautta täysin kuolleeseen. Latvuksen harsuuntuneisuus eli neulaskato arvioitiin asteikolla 0-25 %, 25-50%, 50-75% ja 75-100%. Lisäksi arvioitiin kuusen pihkaantuneisuutta, kirjainpainajien tekemien iskeytymien määrää sekä kaarnassa tapahtuneita muutoksia luokittelemalla ne kolmeen luokkaan. Jokaiselle terveysparametrille annettiin arvo siten, että 1 kuvaa parametrin kannalta tervettä puuta ja parametrin riippuen 3 tai 4 mahdollisimman sairastunutta tai kuollutta puuta.

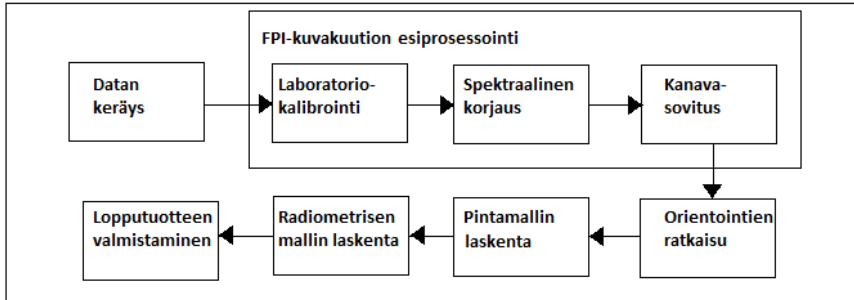


Kuva 11 Koealoilla olleet puut on identifioitu numeroimalla(© Roope Näsi).

4 Menetelmät

4.1 FPI-kuvien prosessointi

Jotta kuvilta voidaan tunnistaa ja tuottaa karttoja tuhoalueista, on kuvat prosessoitava. Tähän prosessointiin liittyy monia vaiheita. Honkavaara ym. (2012, 2013) ovat kehittäneet prosessointiketjun, jolla FPI-kuvista saadaan laskettua reflektanssikuvia (Kuva 12).



Kuva 12 FPI-kameran spektridatan prosessointiketju (muokattu lähteestä Honkavaara ym. 2013)

Ensimmäisenä vaiheena on datan kerääminen eli tässä tapauksessa kuvausten tekeminen ja tallentaminen. Tämän jälkeen on tehtävä FPI-kuvien luonteesta johtuva esiprosessointi, joka sisältää laboratoriokalibroinnin, spektraalisen korjauksen sekä kanavasovituksen tekemisen. Tämän jälkeen on selvitetävä orientoinnit, tuotettava tiheät pintamallit kuvansovituksella, laskettava radiometrisen mallin ja reflektanssimosaikit ennen viimeistä vaihetta eli lopputuotteen valmistamista ja analysointia. (Honkavaara ym. 2013)

4.1.1 Radiometrian korjaus laboratoriokalibroinnilla

Laboratoriokalibroinnilla on tarkoitus poistaa sensorista johtuvat vääristymät, kuten CMOS-kennon epähomogenisuudesta ja vinjetoinnista aiheutuneet virheet. Kalibrointiparametrit on määrittänyt VTT käyttämällä yleisesti valon ominaisuuksien mittaamiseen käytettävää integroivaa palloa.


Radiometriseen korjauksen tekemiseksi kuvilta vähennetään myös pimeävirtakuva (dark signal). Pimeävirtakuva täytyy ottaa aina hieman ennen datan keräämisen aloittamista, sillä sensori reagoi eri olosuhteiden, kuten lämpötilan ja kosteuden, vaikutuksesta aina hieman eri tavalla. (Mäkynen ym. 2011, Honkavaara ym. 2013)

4.1.2 Spektraalisen vääristymän korjaus

FPI-kameran optiikka on suunniteltu siten, että valonsäteet kulkisivat suoraan FPI-yksikön läpi. Aukkosuhteen parantamiseksi on kuitenkin sallittu enimmillään 10 asteen kulma FPI-yksikön läpi kulkevalle säteelle. Tämän takia keskiaallonpituus muuttuu kuvilla siten, että keskellä kuvaa aallonpituus on suurempi kuin kuvan reunoilla (Kuva 13). Tätä ilmiötä kutsutaan myös termillä ”spectral smile” (spektraalinen hymy). Yleisesti keskiaallonpituus (λ_0) on lineaarisesti riippuvainen FPI-yksikön läpi kulkevan säteen kulman kosinista (θ):

$$\lambda_0 \theta = 2 * d * \frac{\cos \theta}{m}, m \in Z_+ \quad (5)$$

jossa d on FPI-peilien ilmarako ja m FPI:n käyttämän interferenssin kertaluku.



Kuva 13 Esimerkkikuvassa keskiaallonpituudet on skaalattu sateenkaarenväreihin, jotta ”spectral smile” –ilmiö näkyisi hyvin. Keskellä kuvaa valkoiset pikselit vastaavat keskiaallonpituutta 711nm. Kohti reunoja mentäessä keskiaallonpituus laskee niin, että sininen väri vastaa arvoa 704 nm.

Tällaisen spektraalisen vääristymän korjaamiseksi on eri vaihtoehtoja. Ensinnäkin yksittäiset kuvat voidaan korjata käyttämällä kahta toisiaan spektraalisesti ja spatiaalisesti lähekkään oleva kanavaa. VTT on kehittänyt tällaisen menetelmän. Siinä valitaan ensin kaksi yhdistettävää kanavaa, jotka sovitetaan ensin keskenään korrelaatioon perustuvilla siirroilla päällekkäin, kanavien eri valotusajankohdasta johtuvan liikkeen poistamiseksi. Tämä liike ei saa olla liian suuri, vaan oltava esim. alle 20 pikseliä, sovituksen onnistumiseksi. Korjattu kuva lasketaan sitten interpoloimalla yhdistettävien kanavien aallonpituuksia tavoitteena olevaan aallonpituuteen. Tässä menetelmässä kanavien lukumäärä pienenee alkuperäisestä, sillä kaikille alkuperäisille kanaville ei löydy riittävän lähellä sekä spektraalisesti että spatiaalisesti olevaa kanavaa. (Mäkyinen ym 2011, Honkavaara ym 2013)

Toinen vaihtoehto on käyttää ainoastaan kuvien keskiosia lopullisissa sovelluksissa. Jotta näin voidaan tehdä, on peitto prosenttien oltava vähintään 60 %. Tällöin ”spectral smile” –ilmiö on niin pieni (alle 5 nm), että sen vaikutus voidaan useimmissa sovelluksissa jättää huomiotta. (Honkavaara ym. 2013)

4.1.3 Kanavasovitus

Kuten luvussa 2.3 kerrottiin, lähes jokainen kanava on valotettu eri aikaan, joten yhden datakuution kanavat eivät ole täydellisesti päällekkäin. Yhden kanavan valotus ja tallentaminen muistikortille vie noin 0,075 s, joten yhden kuvakuution tallentaminen kestää 1,8 s, mikäli tallennetaan kanavia 24 eri ilmaraon arvolla. Tänä aikana kuvauslaite ehtii liikkua jo melko paljon, mikä aiheuttaa haasteita kanavasovitukselle.

Honkavaara (ym. 2013) on kehitellyt menetelmiä tämän ongelman ratkaisemiseksi. Eräs tapa on käsitellä kaikki mielenkiinnon kohteena olevat kanavat erikseen. Tällöin jokaisen kanavan orientointi- ja georeferointiparametrit ratkaistaan yksitellen, mikä on aikaa vievää, mikäli kanavia on runsaasti.

Toinen vaihtoehto on käyttää yhtä kanavista referenssikanavana ja sovittaa muut kanavat siihen. Tätä varten täytyy määrittää sovitettavan kanavan ja referenssikanavan väliset

muunnosparametrit. Muunnosparametrien määrittämiseksi mitataan kanavien välisiä automaattisia liitospisteitä. Kanavien välisten liitospisteiden löytäminen mittaamisessa haastetta aiheuttaa se, että eri kanavien tuottamat pikseliarvot ovat hyvinkin erilaisia. Lisäksi kanavien yhteinen alue saattaa jäädä melko pieneksi, johtuen kuvausalueen nopeasta liikkeestä suhteessa maanpintaan. Myös kolmiulotteisten kohteiden, kuten puiden, kuvautuminen kaksikulotteisella kuvalla on keskusprojektiokuvauksesta johtuen erilaista kuvan keskeillä ja reunoilla, mikä sekin hankaloittaa ajallisesti kaukana toisistaan olevien kanavien soveltamista

Edellä mainittuja vaihtoehtoja voidaan myös yhdistää siten, että valitaan muutama referenssikanava, ratkaistaan niiden orientoinnit ja sovitetaan loput kanavat niihin. Tällöin sovituksen tarkkuus paranee mutta orientointien selvittämiseen ei mene valtavasti aikaa.

Kanavien välisten automaattisten liitospisteiden määrittämiseen voi käyttää mm. Förstnerin operaattoria. Kuvien välisenä muunnoksena voi käyttää affiinia tai projektiivista mallia. (Honkavaara ym. 2013)

4.1.4 Orientointien selvittäminen ja pintamallin laskenta

Kuvien ulkoisten orientointien selvittäminen tarkoittaa kuvan projektiokeskuksen sijainnin (X, Y, Z) ja asennon eli koordinaattiakselien kiertojen (ω, φ, κ) ratkaisemista. Geodeettisella laitteella on kehitetty erityisesti UAV-laitteilla kuvatuille blokeille prosessi ulkoisten orientointien ratkaisemiseksi (Markelin ym. 2014). Ensimmäisessä vaiheessa likimääräiset orientointitiedot ratkaistaan ensin Wun (Wu ym. 2011, Wu 2013) kehittämällä VisualSFM –ohjelmalla. Tämän jälkeen likimääräiset orientointitiedot viedään fotogrammetriseen blokkitasoitusohjelmistoon, jossa ulkoisen orientoinnin parametreja tarkennetaan. Tässä työssä käytettiin kaupallista BAE Systemsin SocetGXP-ohjelmistoa. Lisäksi kameran sisäisen orientoinnin parametreja voidaan ratkaista itse-kalibroinnin avulla. Viimeisenä vaiheena on pintamallin laskenta, johon voidaan käyttää Stuttgartin yliopistossa kehitettyä SURE-ohjelmistoa (Rothermel ym. 2012). Ohjelmisto hyödyntää pistepilven luomisessa Hirschmüllerin (2005) kehittämää SGM-algoritmia (semi-global matching). Pintamalli on mahdollista ratkaista SURE-ohjelmistolla myös heti VisualSFM –laskennan jälkeen. Pintamallin ratkaisemiseen on mahdollista käyttää myös tähän ohjelmistoon sisältyvää NGATE-algoritmia (Next Generation Automatic Terrain Extraction).

VisualSFM (SFM on lyhenne sanoista Structure From Motion) etsii ensin ohjelmaan syötetyiltä kuvilta vastinpiirteitä SIFT-algoritmin (Lowe, 1999) avulla. Mikäli kameran sisäinen orientointi on tiedossa, se voidaan syöttää ohjelmalle mutta ohjelma voi ratkaista blokin myös ilman näitä tietoja. Vastinpiirteiden löytymisen jälkeen aloitetaan varsinainen ulkoisten orientointien ratkaiseminen sädekimpputasoituksena, joka toteutetaan moniytimisenä (Multicore Bundle Adjustment) laskenta-ajan säästämiseksi. VisualSFM ei tarvitse ulkoisten orientointien likiarvoja. Tämä johtuu siitä, että SFM perustuu DLT:hen (direct linear transformation, suora lineaarinen muunnos) eikä epälineaarisiiin kollenaarisuusyhtälöihin kuten perinteiset blokkitasoitusmenetelmät. Sädekimpputasoituksen jälkeen on tiedossa paitsi kameroiden keskinäiset orientointitiedot myös harva pistepilvi maastosta. Absoluut-

tisen orientoinnin selvittämiseksi on vielä tiedettävä joko maastotukipisteiden tai kuvanotopaikkojen kohdekoordinaatteja, jotta mallikoordinaatistosta päästään tunnettuun kohdekoordinaatistoon. (Wu ym. 2011)

SocetGXP on BAE Systemsin perinteinen fotogrammetrinen ohjelmisto orientointien ratkaisuun sisältäen myös kattavat virheanalyysit löydettyjen ratkaisujen tarkkuudelle. SocetGXP:n osana on myös NGATE-ohjelma maastomallin ratkaisemista varten. NGATE-ohjelma käyttää vastinpisteiden etsimiseen sekä ikkuna- että reunapohjaisia menetelmiä (BAE Systems 2007).

SURE –ohjelmisto laskee tiheän pistepilven, kunhan orientointitiedot ovat selvillä. Ohjelmiston käyttämän SGM-algoritmin perusideana on sovittaa yksittäisiä pikseleitä toisiinsa eteenpäinleikkauksen laskemiseksi toisin kuin useamman pikselin ikkunaa hyödyntävissä menetelmissä, kuten NGATE:ssa. Yksittäisten pikselien informaatio ei kuitenkaan aina riitä yksikäsitteiseen ratkaisuun, joten algoritmiin on lisätty pinnan tasaisuuteen liittyviä rajoitteita (Hirschmüller 2005).

4.1.5 Ortokuvablokin radiometrinen korjaus

Kuvablokin radiometriset korjaukset on tehtävä, sillä kuvien valaistusolosuhteet saattavat vaihdella huomattavastikin kuvauksen aikana. Lisäksi tärkeänä tavoitteena on saada yhteys kuvalle tallentuneen harmaasävyarvon (DN) ja kohteen reflektanssin välille.

Yleisesti kaukokartoituksessa, varsinkin kuvausalustan ollessa satelliitti, tästä vaiheesta käytetään nimitystä ilmakehäkorjaus ja korjauksen tekemiseen käytetään säteilynkuljetuksen (radiative transfer) teoriaa. Etenkin UAV-pohjaisissa kartoituksissa on kuitenkin käytetty myös muita menetelmiä, kuten empiirinen viiva –menetelmää (Smith ja Milton 1999) harmaasävyarvon ja reflektanssin välisen yhteyden löytymiseksi. Empiirinen viiva –menetelmää käytettäessä tarvitaan vähintään kaksi referenssikohdetta, joiden heijastusominaisuudet tunnetaan. Nämä tiedot voidaan saada maastomittausten avulla tai sopivista spektrikirjastoista. Tämän jälkeen mitataan vastaavien kohteiden harmaasävyarvot ja sovitetaan pisteisiin suora pienimmän neliösumman menetelmällä ja saaduilla suoran parametreilla muutetaan koko kuva reflektanssikuvaksi kaavan 6 mukaan:

$$\rho = a * DN + b \quad (6)$$

jossa ρ on reflektanssi, DN kuvan harmaasävyarvo sekä a ja b sovitetun suoran parametrit.

Valaistusolosuhteiden muutoksista johtuvaan kuvien epähomogeenisuuden poistamiseen on myös täytynyt kehittää menetelmiä. Eräs keino tämän ongelman ratkaisemiseksi on Honkavaaran ym. (2013) kehittämä radiometrinen blokkitasoitus. Tässä menetelmässä käytetään havaintoina usealla kuvalla näkyvien radiometristen liitospisteiden harmaasävyarvoja. Havainnot tasoitetaan sitten painotetulla pienimmän neliösumman periaatteella. Painoina käytetään havaintojen keskihajontoja. Menetelmän käyttämisen edellytyksenä on, että mm. se että blokin orientointiparametrit sekä maastomalli on jo ratkaistu.

Kehitettyssä menetelmässä huomioidaan myös BRDF-korjaus. Menetelmässä harmaasävy-arvoille (DN) lasketaan arvo kaavalla:

$$DN_{jk} = a_{rel_j}(a_{abs}R_{jk}(\theta_i\theta_r\varphi)+b_{abs}) + b_{rel_j} \quad (7)$$

jossa $R_{jk}(\theta_i\theta_r\varphi)$ on pisteen k ja kuvan j kaksisuuntainen heijastustekijä (BRF). θ_i, θ_r ovat auringon ja havaitsijan zeniittikulmat ja $\varphi = \varphi_r - \varphi_i$. (ks. Kuva 6) Parametrit a_{abs} ja b_{abs} ovat empiirinen viiva –menetelmän antamat parametrit harmaasävyarvojen muuntamiseksi reflektanssiksi sekä a_{rel_j} ja b_{rel_j} ovat tasoitetut suhteelliset (eli relatiiviset) korjausparametrit.

Menetelmässä oletetaan $R_{jk}(\theta_i\theta_r\varphi)$:n ja vastaavan heijastustekijän nadiirigeometriassa $R_k(0,0,\varphi)$:n olevan suoraan verrannollisia vastaaviin mallinnettuihin kaksisuuntaisiin heijastusfunktioihin (BRDF) eli:

$$R_{jk}(\theta_i\theta_r\varphi) = R_k(0,0,\varphi)\rho(\theta_i\theta_r\varphi)/\rho(0,0,\varphi) \quad (8)$$

jossa $\rho(\theta_i\theta_r\varphi)$ on kaksisuuntainen heijastusfunktio yleisessä mittausgeometrian tilanteessa ja $\rho(0,0,\varphi)$ vastaava funktio nadiirigeometrian tapauksessa. BRDF-mallina menetelmässä käytetään Walthallin (1985) esittelemää yksinkertaista funktiota, jolloin lopulliseksi ratkaistavat vakiot a ja b sisältäväksi kaksisuuntaiseksi heijastustekijäksi saadaan:

$$R_{jk}(\theta_i\theta_r\varphi) = R_k(0,0,\varphi)(a\theta_r^2 + b\theta_r \cos \varphi + 1) \quad (9)$$

Tässä mallissa absoluuttisen kalibrointien parametrit a_{abs} ja b_{abs} huomioivat ilmakehän vaikutuksen, BRDF-mallin parametrit a ja b mittausgeometrian (ks Kuva 6) vaikutuksen sekä suhteellisen korjauksen parametrit a_{rel_j} ja b_{rel_j} valaistusolosuhteiden muutoksen vaikutukset. Mallissa ennen tasoitusta tuntemattomia parametreja ovat suhteellisen korjauksen parametrit, joiden lukumäärä on (kuvien lukumäärä -1)*2 sekä 2 kpl BRDF-mallin parametreja. Tasoituksessa havaintoina käytettäviä radiometrisiä liitospisteitä täytyy jokaisella kuvalla näkyä vähintään 2 kpl, jotta tasoitus onnistuu. Mallia on mahdollista käyttää myös niin, että BRDF-korjausta ei huomioida tai siten, että ainoastaan toinen (a_{rel_j}) suhteellisen korjauksen parametreista ratkaistaan. Kun tasoitus on laskettu, ratkaistaan haluttu suure eli reflektanssi nadiirigeometriassa ($R_k(0,0,\varphi)$) kaavojen 7 ja 9 avulla ja kirjoitetaan tällä tavoin saadut arvot ortokuvaa vastaavaksi reflektanssimosaikiksi. (Honkavaara ym. 2013)

Valaistusolosuhteiden muutosten eliminoimiseksi on kehitetty myös muita menetelmiä. Hakala ym. (2013) ovat kehittäneet menetelmän, joka käyttää hyväksi maasta kerättyä irradianssidataa. Tässä menetelmässä jokaiselle kuvalle ja kanavalle lasketaan korjauskerroin $C_j(\lambda)$ kaavalla:

$$C_j(\lambda) = E_j(\lambda)/E_{ref}(\lambda) \quad (10)$$

jossa $E_j(\lambda)$ on kuvanottohetken spektraalinen irradianssi ja $E_{ref}(\lambda)$ referenssikuvan vastaava arvo. $C_j(\lambda)$ voidaan sitten sijoittaa kaavaan (7) a_{rel_j} :n paikalle. Valaistusolosuhteiden

muutosta voi eliminoida myös laskemalla kuvien harmaasävyarvojen keskiarvot ja laskea kaavaa 10 vastaava korjauskerroin jakamalla tämän keskiarvon referenssikuvan keskiarvolla.


4.2 Yksittäisten puiden tunnistaminen

Yksittäisten puiden tunnistaminen kuvilta oli tärkeää, sillä maastohavainnot oli tehty puukohtaisesti ja lisäksi tutkimuksen yhtenä tavoitteena oli tuottaa puukohtaisia tuhokarttoja alueesta. Puiden tunnistamista voidaan tehdä laserkeilauksella tai kuvilta tuotetun pintamallin tai pelkästään kuva-analyysin perusteella. Pintamalliin perustuvissa menetelmissä puiden tunnistaminen perustuu usein paikallisten maksimien etsintään ja kuva-analyysiin perustuvissa kuvan segmentointiin eli kuvan jakamiseen useista pikseleistä koostuviin samankaltaisiin alueisiin.

Erityisesti laserkeilausaineistoja on käytetty pintamalliin perustuvissa puiden tunnistusmenetelmissä runsaasti vuodesta 1999 lähtien (Hyypä ja Inkinen, 1999). Kaartinen ym. (2012) ovat vertailleet useiden tällaisten algoritmien toimintaa. Useissa tällaisissa algoritmeissa analysoidaan pinta- ja maastomallin erotuksena syntyvää latvusmallia (CHM, canopy height model) ja etsitään siitä erilaisten suodatusten jälkeen paikallisia maksimeita. Laserkeilaukseen perustuvissa menetelmissä voidaan käyttää hyväksi myös muita keilauksesta saatavia tietoja, kuten pulssiin intensiteettiä. Näitä menetelmiä voidaan soveltuvin osin käyttää myös fotogrammetrisesti tuotetuille pintamalleille.

Kuva-analyysiin perustuvaan puiden tunnistamiseen on käytetty mm. segmentointiin perustuvia menetelmiä (esim. Uuttera ym. 1998). Puiden keskipisteiden haussa kuvilta voidaan käyttää myös hyväksi sitä, että metsässä puiden latvat ovat kuvilla kirkkaampana kuin muuta alueet. Pitkänen (2001) on käyttänyt tätä hyväksi puiden tunnistamisessa ja kehittänyt menetelmän, jossa puut tunnistetaan harmaasävyarvojen paikallisten maksimien avulla. Ennen maksimien hakua kuvaa kuitenkin suodatettiin (smoothing).


Tässä työssä puiden keskipisteiden tunnistamiseen FPI-kuvilta kehitettiin menetelmä, joka hyödyntää sitä, että latvat näkyvät kuvilla kirkkaampana. Ensimmäisessä vaiheessa kuva luokiteltiin automaattisesti ohjaamattomalla k-means –luokittelulla 10 luokkaan. Luokittelun tuloksena pikselit luokittuivat kirkkaasta puun latvasta kohti tummempia puun alaosia ja varjoja (Kuva 14). Tämän jälkeen luokittelukuvalta puiden keskipisteet voitiin etsiä hakemalla paikalliset maksimit.



Kuva 14 Vasemmalla 24-kanavaista FPI-kuvamosaiikkia esitettyä väärävärinä ja oikealla ohjaamattoman luokituksen tulokset. Kuvassa vaaleimmat latvat ovat luokassa 10 ja tummimmat alueet eli varjot luokassa 1.

4.3 Testipuiden spektrien laskeminen

Koealoilla olevat testipuut oli tärkeä tunnistaa kuvilta, jotta voitiin verrata maastohavaintojen ja spektrien vastaavuutta. Koealojen keskipisteet oli paikannettu GPS-laitteella sekä koealojen puiden etäisyydet ja suunnat mitattu, kuten luvussa 3.2 kerrottiin. Näillä tiedoilla voitiin laskea kunkin testipuun kuvakoordinaatit eranto vielä huomioiden, sillä suunnat oli mitattu bussolilla eli tarkkuuskompassilla. GPS:n paikannustarkkuus ei kuitenkaan metsäisissä olosuhteissa ollut täysin tarkka. Tämän takia lasketut koepuiden koordinaatit eivät osuneet kaikilta osin kuvilla näkyvien latvojen päälle. Tutkimuksen kannalta oli hyvin tärkeää saada koepuiden spektrit, joten jokainen koealan koordinaatit käytiin manuaalisesti läpi ja tehtiin tarvittaessa pieni siirto koealan keskipisteen koordinaatille, jotta puiden koordinaatit saatiin kohdistettua latvoihin. Tehtyjen siirtojen määrittämisessä käytettiin hyväksi sekä spatiaaliselta resoluutioltaan tarkempaa RGB- että FPI-ortokuvaa.



Kuva 15 Vasemmalla alkuperäiset erään koealan puiden sijainnit RGB-ortokuvalla ja oikealla sijainnit koealan keskipisteen manuaalisen siirron jälkeen.

Kuva 15 on erään koealan puiden sijainnit ennen ja jälkeen koealan keskipisteen siirtoa. Siirrossa voitiin käyttää apuna maastosta kerättyjä tietoja. Esimerkiksi puun 461 tiedettiin olevan kuollut, jolloin tämän tiedon avulla tehdyn siirron jälkeen myös muiden puiden koordinaatit osuivat aiempaa paremmin puiden latvoihin.

Saatujen testipuiden kuvakoordinaattien avulla laskettiin kullekin puulle spektri. Tämä tehtiin laskemalla puille keskiarvoreflektanssi jokaiselta kanavalta 3*3 pikselin kokoisen ikkunan alueelta. Maastossa ikkunan koko on 1,5*1,5 m, sillä FPI-kuvien GSD oli 0,5 m.

4.4 Puiden luokittelu terveyslukkiin ja luokittelun arviointi

Työn tavoitteena oli kartoittaa kirjanpainajien sairastuttamat ja tappamat puut koko tutkimusalueella. Tavoitteen saavuttamiseksi käytettiin jo luvussa 2.4.3 esiteltyjä ohjatun luokittelun algoritmeja siten, että opetusaineistona käytetään koealoilta saatuja puiden spektrejä, jotka luokitellaan haluttuihin ryhmiin maastossa kerättyjen kuusten terveysparametrien

avulla. Luokittelussa käytettiin neljää eri luokittelualgoritmia, jotka ovat pienimmän etäisyyden, suurimman uskottavuuden, SAM- ja SCM-algoritmit, jotta voitiin tutkia mikä algoritmeista sopii parhaiten tämänkaltaisen aineiston luokitteluun. Luokittelun toteutukseen käytettiin kaupallista Erdas Imagine –kaukokartoitusohjelmistoa.

Luokittelun onnistumisen arvioimiseksi on olemassa muutamia menetelmiä. Yksinkertaisin menetelmä on esittää ns. virhematriisi, jonka avulla voidaan määrittää oikeinluokitusprosentit. Virhematriisissa esitetään kullakin rivillä oikeat luokat ja sarakkeilla luokittelijan antamat luokat. Virhematriisista nähdään siis helposti myös mitkä luokat näyttävät sekoittuvan keskenään. Optimaalisessa tilanteessa luokittelijan opetusaineisto ja testausaineisto ovat erillisiä aineistoja mutta usein tämä ei ole mahdollista, sillä maastosta saatuja havaintoja on niin vähän, että kaikki mahdollinen aineisto käytetään luokittelijoiden opettamiseen. Tämän ongelman ratkaisemiseksi on kehitetty myös ns. leave-one-out –ristiinvaldointi, jossa opetusaineistona käytetään vuorotellen kaikkia muita paitsi yhtä havaintoa ja tätä käyttämättä jäänyttä käytetään sitten luokittelijan testaukseen. Luokittelun tarkkuuden arviointiin on kehitetty myös virhematriisin perusteella laskettava Cohenin kappa-arvo (Cohen, 1968), joka kertoo, miten paljon parempi luokittelutulos on verrattuna täysin satunnaiseen luokitteluun. Kappa-arvo lasketaan kaavalla:

$$K = \frac{\sum_{i=1}^r n_{ii} \sum_{i=1}^r R_i C_i}{N^2 - \sum_{i=1}^r R_i C_i} \quad (11)$$

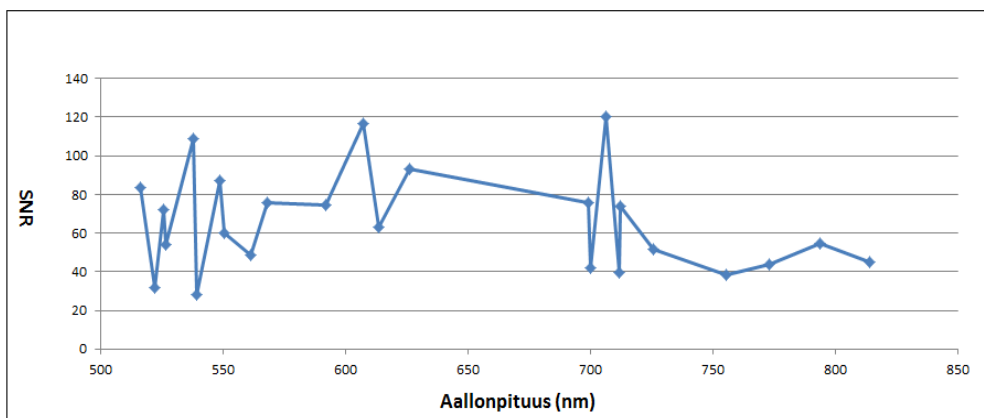
jossa N on kaikkien havaintojen lukumäärä, r virhematriisin rivien lukumäärä, n_{ii} virhematriisin päälävistäjän arvo, R_i matriisin rivin ja C_i matriisin sarakkeen arvo. (Lillesand ym. 2008, s. 589-592)

5 Tulokset

5.1 Kuvien laatu

Kuvien kohinaisuutta tutkittiin, jotta voitiin vertailla, onko kanavien välillä eroja kuvan laadussa. Tätä tutkittiin laskemalla jokaisen kanavan signaalikohinasuhde (signal-to-noise ratio, SNR). Tämä tehtiin maastoon sijoitetun tasaisen referenssilevyn avulla (P10-levy) siten, että kavalta laskettiin referenssikohteen signaalin keskiarvon ja keskihajonnan suhde pienen ikkunan alueella. Tämä ei ole tarkin mahdollinen tapa signaalikohinasuhteen laskemiseen, sillä referenssilevyssäkin voi olla pientä epähomogeenisuutta. Suhteellisista eroista kanavien välillä tällä tavalla saadaan kuitenkin realistinen kuva.

Signaalikohinasuhde vaihtelee kanavittain suurimmilta osin 40 ja 100:n välillä (Kuva 16). Tulosta voidaan pitää odotettuna, sillä samankaltaisia tuloksia on saatu myös aiemmissa tällä kameralla tehdyillä mittauksilla (mm. Honkavaara ym. 2013).



Kuva 16 Signaalikohinasuhde laskettuna kanavittain tasaisen referenssilevyn avulla

5.2 FPI-kuvien esiprosessointi


FPI-kuville on tehtävä esiprosessointia niiden luonteen vuoksi. Esiprosessointiin kuuluvat radiometrien korjaus laboriokalibrointiin perustuen, spektraalisen vääristymän korjaus sekä kanavasovitus. Näistä kaksi ensin mainittua on tehty VTT:n kehittämällä menetelmillä ja ohjelmilla (Mäkynen ym. 2011) sekä jälkimmäinen Honkavaaran (ym. 2013) menetelmällä.

5.2.1 Radiometrian korjaus laboriokalibroinnilla

Laboriokalibroinnilla on tarkoitus poistaa sensorista johtuvat radiometrian virheet. Siinä kuvilta poistetaan juuri ennen kuvausta otettu pimeävirtakuva sekä huomioidaan muut epätasaisuudet käyttämällä kalibrointitiedostoa, jonka VTT on määrittänyt kuvaamalla mahdollisimman diffuusia pintaa, kuten integroivaa palloa.

Alkuperäisissä integroivan pallon avulla tehdyissä kalibrointitiedostoissa havaittiin olevan puutteita, sillä käsitellyissä kuvissa näkyi joitain säännöllisiä epätasaisuuksia. Tämän vuoksi VTT määrittäi uusia kalibrointitiedostoja sekä integroivalla pallolla että muilla me-

netelmillä. Kalibrointitiedostojen eroja tutkittiin kuvaamalla FPI-kameralla mahdollisimman diffuusiksi oletettua levyä siten, että kameraa kierrettiin jokaisen kuvan välissä aina 90°. Näistä kuvista laskettiin keskiarvokuva, jotta kuvatun pinnan mahdolliset pienet epätasaisuudet ja kohina saatiin poistettua. Keskiarvokuvassa näkyvien epätasaisuuksien pitäisi siis johtua ainoastaan käytetystä kalibrointitiedostosta. Keskiarvokuvien lisäksi laskettiin ns. kalibrointikuvat, joissa kullekin pikselille laskettiin sellainen korjauskerroin, että kuva olisi täysin tasainen. Korjauskerroin on laskettu siten, että kuvan keskimäinen pikseli saa arvon 1. Lopuksi korjauskertoimet on vielä kerrottu 10000, jotta kuva voidaan esittää 16-bittisellä kuvalla. Tehtyjen testien perusteella epätasaisuudet olivat hieman erilaisia eri kanavilla. Uudempi integroivalla pallolla tehty kalibrointitiedosto tuotti tasaisempia tuloksia (vaihtelu n. 6 %) kuin muut, joissa tasaisuus kuvan reunojen välillä oli jopa yli 10 %. Tämän takia myös kirjanpainajatuhoista otetut kuvat prosessoitiin tällä parhaaksi todetulla kalibrointitiedostolla.



Kuva 17 Esimerkkikuva kalibrointitiedostojen testauksesta käytetystä kalibrointikuvasta sekä vasemmasta alakulmasta oikeaan yläkulmaan vedetyn linjan profiili. Tässä kuvassa epätasaisuus on n. 7% (kuvaajassa arvot vaihtelevat 9400 ja 10100 välillä).

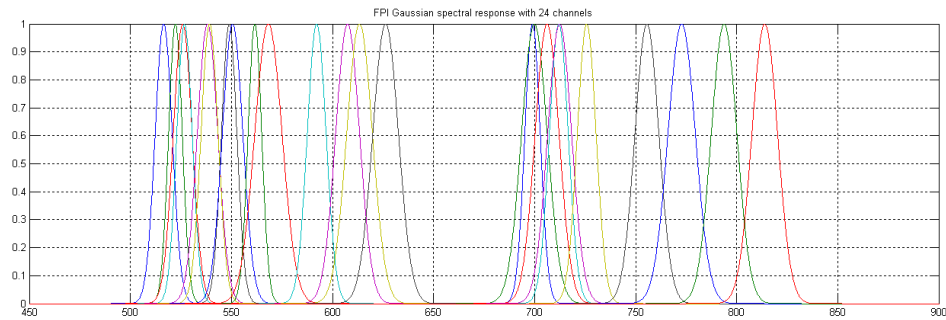
5.2.2 Spektraalisen vääristymän korjaus

Spektraalisen vääristymän korjaamiseksi esiteltiin luvussa 4.1.2 kaksi vaihtoehtoa eli VTT:n kehittämä menetelmä spektraalisesti lähellä olevien kanavien yhdistäminen sekä ainoastaan kuvan keskiosan, jossa spektraalinen vääristymä on vähäistä, käyttäminen reflektanssimosaikin laskennassa. Vääristymän korjaamiseksi päädyttiin käyttämään kanavien yhdistämistä, vaikka tällöin kanavien lukumäärä pienenee. Tässä tapauksessa kanavien määrä putosi alkuperäisestä 41 kanavasta 24 kanavaan, minkä vaikutus näkyy erityisesti 630-690 nm:n alueella, sillä siellä ole korjauksen jälkeen kanavia lainkaan. Korjauksen jälkeen käytössä olleiden kanavien aallonpituudet ja puoliarvoveydet on esitetty Taulukko 4 ja havainnollistettu Kuva 18.

Taulukko 4 Spektraalisen korjauksen jälkeen käytössä olleiden kanavien aallonpituudet ja puoliarvoveydet (vrt. taulukko 3)

Spektraalisesti korjattu data	
Aallonpituus (nm)	516.50, 522.30, 525.90, 526.80, 538.20, 539.20, 548.90, 550.60, 561.60, 568.30, 592.20, 607.50, 613.40, 626.30, 699.00, 699.90, 706.20, 712.00, 712.40, 725.80, 755.60, 772.80, 793.80, 813.90

Puoliarvoväleveys (nm) 10.00, 8.00, 11.00, 9.00, 12.00, 10.00, 9.00, 12.00, 8.00, 16.00, 11.00, 14.00, 15.00, 15.00, 9.00, 15.00, 14.00, 11.00, 14.00, 11.00, 14.00, 16.00, 15.00, 15.00




Kuva 18 Normalisoidut spektrivasteet spektraalisen korjauksen jälkeen (Vrt. Kuva 10)

5.2.3 Kanavasovitus

Kanavasovituksen avulla kanavien eriaikaisesta valotuksesta johtunut liike poistettiin asettamalla kanavat päällekkäin. Kanavasovitus tehtiin Honkavaaran (2013) kehittämällä menetelmällä ja ohjelmalla. Referenssikanavaksi, johon muut kanavat sovitetaan, valittiin spektraalisen korjauksen jälkeen käytössä ollut kanava 14, joka vastaa valotushetkeltään ennen spektraalista korjausta ollutta kanavaa 21, jonka suhteen orientoinnit ratkaistiin (ks. seuraava luku). Kanava 14 valittiin referenssikanavaksi, sillä se oli käytössä olevien kanavajakauaman melko keskellä sekä aallonpituuden että valotusajan suhteen. Tämä oli tärkeää sovituksen onnistumisen kannalta, sillä tällä tavoin tarvittavat siirrot ovat mahdollisimman pieniä. Suurin liike kanavien välillä oli tässä tapauksessa n. 85 pikseliä.


Kanavasovituksessa oli mahdollista käyttää myös useampia kanavia referenssikanavina, jolloin sovitettavien kanavien liike olisi ollut pienempää. Sovittaminen yhteen kanavaan onnistui kuitenkin tässä tapauksessa niin hyvin, että päädyttiin sen käyttämiseen, koska seuraavat käsittelyn vaiheet ovat tällöin yksinkertaisempia. Kanavasovituksen vaikutuksen voi havaita visuaalisesti (Kuva 19).



Kuva 19 Vasemmalla esitetty yksittäisen kuvakuution kanavat 23, 11 ja 3 päällekkäin ennen kanavasovitusta ja oikealla vastaavat kanavat kanavasovituksen jälkeen.


5.3 Orientointien ratkaisu

Ulkoisten orientointien ratkaiseminen aloitettiin VisualSFM-ohjelmalla, jolla saatiin likiarvot ulkoisten orientointiparametrien tarkempaan ratkaisuun. RGB-kuvien kokoa jouduttiin pienentämään alkuperäisestä 6080x4044 pikselistä neljännekseen, jotta käytössä olleen tietokoneen laskentateho riittäisi ratkaisun saamiseksi. FPI-kuvilta irrotettiin ja muunnettiin jpeg-formaattiin yksittäisiä kanavia (ennen spektraalisen vääristymän korjausta olleet kanavat 12, 21, 38) VisualSFM -laskentaa varten. Laskennan tulokset näyttivät visuaalisesti hyviltä (Kuva 20). Absoluuttisen orientoinnin määrittämiseksi käytettiin alun perin projektiokeskusten sijainnista, jotka saatiin lentokoneesta kerätystä GPS-datasta. Myöhemmin tämän paikannustiedon kuitenkin todettiin olevan niin epätarkkaa, että koordinaatistomuunnokseen käytettiin MML:n ortokuvilta mitattuja maastotukipisteitä, joita käytettiin myös SocetGXP:n avulla lasketussa blokkitasoituksessa.



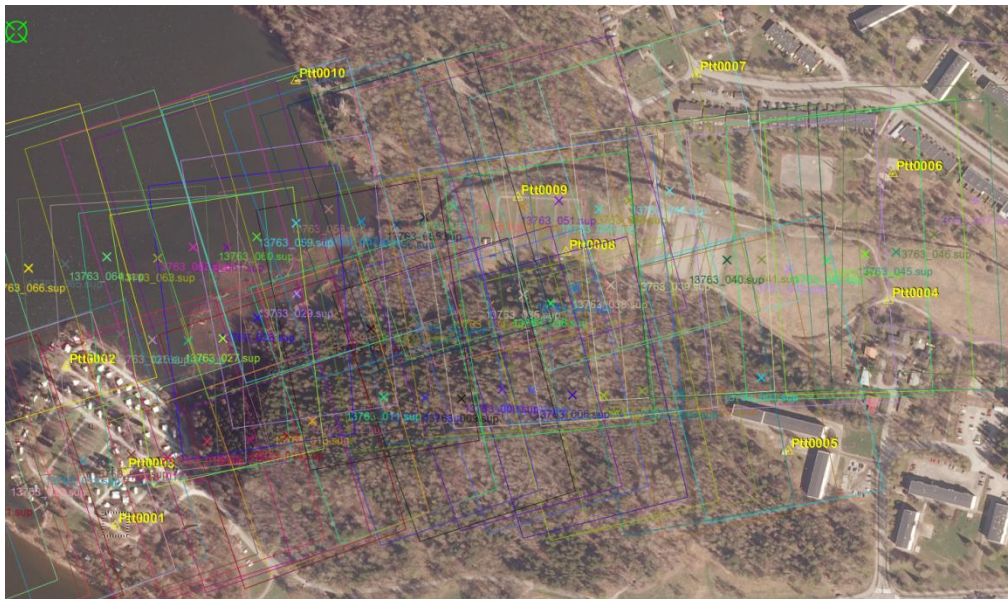
Kuva 20 VisualSFM:llä ratkaistuissa kuvablokeissa näkyvät projektiokeskusten sijainnit sekä harva pistepilvi. Vasemmalla eteläinen RGB-blokki ja oikealla pohjoinen FPI-blokki kanavalta 21 (619,5 nm) Vrt. Kuva 7.

VisualSFM:n antamat ulkoisen orientoinnin parametrit eli projektiokeskusten sijainnit ja kierrot vietiin seuraavaksi likiarvoina SocetGXP:hen. Blokkitasoitukseen tekemistä varten tarvittiin maastotukipisteitä, joita ei ennen kuvauksia ollut mitattu. Luonnollisia maastotukipisteiden tasokoordinaatteja kuitenkin saatiin mittaamalla sopivia kohteita MML:n ortokuvista ja vastaavat z-koordinaatit MML:n laserkeilausaineistosta lasketusta pintamallista. Luonnollisten maastotukipisteiksi soveltuvat pisteet, jotka on tarkasti paikannettavissa sekä MML:n ortokuvilta että blokkitasoituksessa olevilta kuvilta. Tällaisia pisteitä löytyy helpoiten rakennetuilta alueilta, mutta metsäisiltä alueilta niitä on vaikea löytää. Vaatimukset hyvillä pisteillä vaihtuivat hieman riippuen siitä, olivatko kyseessä RGB- vai FPI-kuvat. RGB-kuville hyviä pisteitä olivat mm. katumaalaukset, jotka erotuvat hyvin 5 cm:n GSD:llä olevista kuvista. FPI-kuvista näitä ei näkynyt mutta hyviä pisteitä olivat esimerkiksi kasvillisuuden ja asfaltoitujen alueiden kulmat (Kuva 21).



Kuva 21 Manuaalista maastotukipisteiden mittausta SocetGXP:ssä: vasemmalla MML:n ortokuva ja muissa kuvissa sama piste mitattuna FPI-kuvilta.

Maastotukipisteiden tulisi kattaa mahdollisimman hyvin koko kuvatun blokin alue. Metsäisiltä alueilta ei niitä kuitenkaan ollut mahdollista saada. Esimerkki mitattujen maastotukipisteiden jakaumasta on nähtävissä Kuva 22.



Kuva 22 Kuvassa näkyvät pohjoisen RGB-blokin mitatut maastotukipisteet keltaisella sekä yksittäisten kuvien rajaukset.

Maastotukipisteiden manuaalisen mittaamisen jälkeen SocetGXP:ssä aloitetaan automaattinen liitospisteiden laskenta. Kun ne on mitattu, voidaan aloittaa blokkitasoitus, johon voidaan ottaa mukaan myös sisäisen orientoinnin parametreja itsekalibroinnin laskemista varten. Blokkitasoitusta varten täytyy määrittää havainnoille niiden tarkkuutta kuvaavat painot. Maastotukipisteiden tasotarkkuudeksi arvioitiin 1 m, sillä MML:n (2014a) mukaan ortokuvien sijaintitarkkuus on 0,5-2 m ja korkeustarkkuudeksi 0,5 m, sillä laserkeilauksesta tuotetun korkeusmallin tarkkuudeksi MML (2014b) ilmoittaa 0,3 m. Ulkoisten orientointitietojen paikkojen painoina käytettiin lopulta 15-20 m:ä ja kierroille 3-5° blokista riippuen. Blokkitasoitus laskettiin ensin niin, että ulkoisten orientointien alkulikiarvot oletettiin tarkemmiksi mutta tällöin tasoituksen onnistumista kuvaavat parametrit, kuten maastotukipisteiden residuaalien RMSE-arvot, olivat melko huonoja, minkä päätettiin johtuvan epätarkoista alkulikiarvoista. Useiden laskentakertojen perusteella päädyttiin näiden havaintojen painoina käyttämään edellä mainittuja arvoja.

SocetGXP:llä ratkaistujen blokkien tilastotiedot on esitetty Taulukko 5. Painoyksikön keskivirhe on FPI-blokeilla 0,56 ja 0,80 pikseliä ja RGB-blokeilla 0,8 ja 1,2 pikselin välillä. Projektiokeskusten paikkojen ja kiertojen pns-sovituksen antamien keskihajontojen neliöllisiä keskiarvoja (RMSE) ovat FPI-blokeilla huomattavasti suuremmat kuin RGB-blokeilla. Tämä saattaa johtua mm. RGB-kuvien pienemmästä GSD:stä, jolloin automaattisten liitospisteiden mittaaminen on tarkempaa. Tukipisteiden residuaalien RMSE-arvot ovat 0,5 ja 1,6 m:n välillä, paitsi FPI-blokkien Z-koordinaattien, jotka ovat alle 0,3 m. Nämä ovat jopa epäilyttävän pieniä lukuja varsinkin, kun vertaa laserkeilauksesta ja FPI-kuvista laskettujen maastomallien erotuskuvaa (Kuva 25).

Taulukko 5 Blokkitasoituksen tilastotiedot: painoyksikön keskivirhe (σ), keskihajontojen neliölliset keskiarvot projektiokeskusten sijainneille (RMSE paikat) ja kierroille (RMSE kierrot) sekä maastotukipisteiden jäännösvirheille (RMSE tukipisteet). Lisäksi kyseisen blokin kuvien ja lentojonojen määrä.

Blokki	Kamera kanava	σ (pix)	RMSE paikat m			RMSE kierrot °			RMSE tukipisteet m			kuvia jonoja	
			X0	Y0	Z0	ω	φ	κ	X	Y	Z		
Etelä	FPI/21	0,56	1,81	2,14	0,59	0,24	0,20	0,06	1,02	1,06	0,29	228	11
Pohjoinen	FPI/21	0,80	3,34	2,87	1,15	0,30	0,35	0,10	1,00	0,74	0,24	41	4
Etelä	RGB	1,18	0,82	0,25	1,46	0,00	0,08	0,00	1,60	0,99	0,48	330	7
Pohjoinen 1	RGB	0,81	0,12	0,11	0,03	0,01	0,02	0,00	1,10	0,90	0,42	66	3
Pohjoinen 2	RGB	0,87	0,70	0,78	0,43	0,09	0,08	0,05	0,76	0,53	0,43	40	1

SocetGXP:ssä on mahdollista ottaa vapaasti valittavia sisäisen orientoinnin sekä kuvavääristymiä kuvaavia parametreja mukaan blokkitasoitukseen. Tärkeimmät sisäisen orientoinnin parametrit ovat kameravakio ja pääpisteiden koordinaatit ja kuvavääristymien parametreista radiaalisiin piirtovirheen parametrit. SocetGXP:ssä nämä parametrit ilmoitetaan kuvan keskipisteen suhteen ja k_1 on kolmannen ja k_2 viidennen asteen termin kerroin radiaalista piirtovirhettä kuvaavassa funktiossa. Itsekalibroituja parametreja ei voi ottaa tasoitukseen mukaan liikaa, jotta tasointi ylipäätään onnistuu ja parametri ratkeaa luotettavasti. Parametrin luotettavan ratkeamisen arvioinnissa voi käyttää hyväksi SocetGXP:n antamaa parametrin keskihajontaa, jonka tulee olla huomattavasti pienempi kuin itse parametrin. Lisäksi saatua parametria voi verrata saman kameralle aiempiin tuloksiin vastaavan parametrin ratkaisussa joka on voitu saada myös esimerkiksi laboratoriokalibroinnin avulla.

Ratkaistujen blokkien itsekalibroituja parametreja ja niiden keskihajonnat on esitetty Taulukko 6. RGB-blokeissa saatiin luotettavasti määritettyä kaksi radiaalisen piirtovirheen parametria mutta FPI-blokeissa tämä virhe saatiin määritettyä vain yhden parametrin avulla. Ratkaistut parametrit samalla kameralle ovat hyvin lähellä toisiaan sekä niiden keskihajonnat pieniä, mikä kertoo ratkaisun luotettavuudesta. Ainoana poikkeuksena on RGB-blokki pohjoinen 2, jossa varsinkin pääpisteen x-koordinaatti eroaa muista ratkaisuista merkittävästi ja myös keskihajonta on suurempi kuin muilla vastaavilla. Tämä johtuu luultavasti siitä, että kyseisessä blokkissa oli vain yksi lentojono, jolloin pääpisteen määrittäminen varsinkaan lentosuuntaa vastaan kohtisuorassa suunnassa on vaikeaa, sillä saman pisteen kuvahavaintoja ei ole riittävästi.


Taulukko 6 Itsekalibrointina lasketut sisäisen orientoinnin parametrit: k1 ja k2 radiaalisen piirtovirheen parametrit ja autokollimoidun pääpisteen koordinaatit (PPA x ja PPA y) sekä niiden keskihajonnat.

Blokki	Kamera kanava	Ratkaistut parametrit				Keskihajonnat			
		k1 mm/mm ³	k2 mm/mm ⁵	PPA x mm	PPA y mm	k1 mm/mm ³	k2 mm/mm ⁵	PPA x mm	PPA y mm
Etelä	FPI/21	-0,002550				1,102E-05			
Pohjoinen	FPI/21	-0,002680		-0,07	0,12	2,73E-05		0,01	0,008
Etelä	RGB	0,0000533	-1,2E-08	-0,06	-0,10	1,50E-07	3,33E-10	0,002	0,002
Pohjoinen 1	RGB	0,0000532	1,10E-08	-0,03	-0,23	2,77E-07	5,34E-10	0,004	0,003
Pohjoinen 2	RGB	0,0000535	1,38E-08	-0,26	-0,23	2,99E-07	5,31E-10	0,028	0,022

5.4 Pintamallit

Pintamallit on laskettava, sillä niitä tarvitaan ortokuvien laskemisessa. Niiden avulla on myös mahdollista saada kohteesta geometristä tietoa, kuten kasvillisuuden korkeutta kuvaava latvusmalli (CHM), jonka avulla voidaan mm. tunnistaa yksittäisten puiden sijaintoja. Lisäksi vertaamalla näitä fotogrammetrisesti tuotettuja pintamalleja muihin saman alueen pintamalleihin, kuten laserkeilauksella tuotettuihin, on mahdollista myös arvioida orientointien ratkaisujen tarkkuutta.

Pintamalleja laskettiin molemmilla kappaleessa 4.1.4 esitetyillä menetelmillä eli sekä SocketGXP:n NGATE:lla että Stuttgartin yliopiston kehittämällä SURE:lla. Pintamalleja laskettiin NGATE:lla myös FPI-kuvista mutta ne olivat melko kohinaisia verrattuna RGB-kuvista laskettuun pintamalliin (Kuva 23). Tämä johtunee suurimmilta osin RGB-kuvien pienemmästä GSD:stä. Tämän vuoksi seuraavissa vaiheissa käytettiin RGB-pintamalleja.



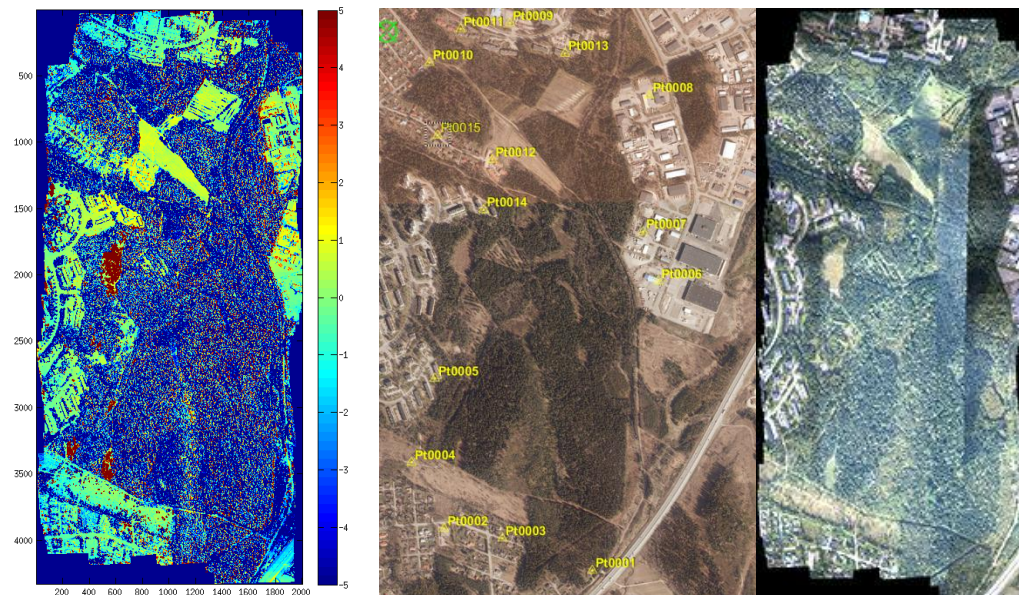
Kuva 23 Vasemmalla FPI-kuvan alkuperäisestä kanavasta 21 NGATE:lla laskettua pintamallia ja oikealla vastaavan alueen RGB-pintamalli.


NGATE:lla hilamuotoisia pintamalleja (grid-malli) laskettaessa täytyy valita hilakoko ja tarkimmat pintamallit laskettiin 20 cm:n hilakoolla (kuva). NGATE:n lisäksi pintamalleja laskettiin myös SURE:lla VisualSFM –laskennan jälkeen. SURE:n tuottamaa tiheää 3D-pistepilveä on nähtävissä (Kuva 24).



Kuva 24 Vasemmalla SURE:n laskennan tuloksena syntynyttä tiheää pistepilvettä ja oikealla NGATE:lla 20 cm:n hilakokoon laskettua pintamallia, jonka päälle on asetettu vielä ortokuva

Orientointien ratkaisun onnistumisen arvioimiseksi vertailtiin saatuja pintamalleja MML:n laserkeilausaineistosta laskettuun pintamallin. Tämä tehtiin laskemalla erotuskuvat, joissa fotogrammetrisesti lasketusta pintamallista on vähennetty laserkeilauksella saatu malli. Erotuskuvat laskettiin sekä RGB- että FPI-kuvista lasketuille pintamalleille (Kuva 25).





Kuva 25 Ylhäällä vasemmalla RGB-pintamallin ja laserkeilauspintamallin erotuskuva eteläisen blokin alueelta, keskellä maastotukipisteiden sijainnit esitettynä MML:n ortokuvalla ja oikealla alueesta valmistettu ortokuva. Alhaalla vastaava erotuskuva sekä maastotukipisteiden jakauma FPI-aineistolla.

Pintamallien erotuskuvista näkee laserkeilaus- ja fotogrammetrisen pintamallin luonteen eron metsäisillä alueilla, joissa fotogrammetrisen pintamalli on laserkeilausmallia ylempänä. Tämä johtuu siitä, että laser tunkeutuu metsässä paremmin maan pintaan saakka kuin valonsäde. Sen sijaan tasaisilla alueilla, kuten pelloilla ja asfaltoiduilla, voidaan arvioida pintamallien eroja luotettavasti. RGB-erotuskuvassa suurimmat erot pintamallien välillä ovat noin yhden metrin, lukuun ottamatta joitain reuna-alueita sekä kuvan keskiosassa tummanpunaisena näkyvää aluetta, jossa puut on kaadettu laserkeilauksen ja tehtyjen kuvausten välillä. FPI-erotuskuvasta nähdään hyvin käytettyjen maastotukipisteiden jakauman vaikutus orientointien ratkaisujen tarkkuuteen, sillä maastotukipisteverkon ulkopuolella erotuskuvassa on jopa 10 metrin arvoja. Sen sijaan maastotukipisteverkon sisällä arvot jäävät pääasiassa alle kahden metrin. Orientointien tarkkuutta näillä reuna-alueilla ei ollut syytä yrittää parantaa, sillä ne olivat tutkimusalueen ulkopuolella.

Kuten työn johdannossa kerrottiin, työtä rajattiin ennen lopullisten analyysien tekemistä. Seuraavissa vaiheissa onkin huomioitu ainoastaan suurempi eteläinen blokki ja sen sisältämät 30 maastokoealaa.

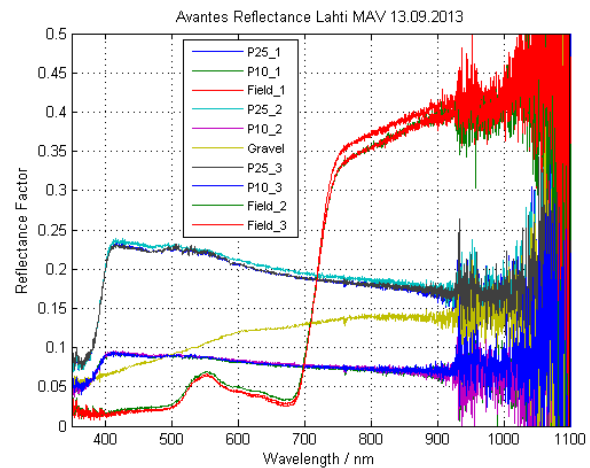
5.5 Reflektanssimosaiikin laskenta

Reflektanssimosaiikilla tarkoitetaan tässä monikanavaista ortokuvamosaiikkia, jossa harmaasävyarvot vastaavat kohteen reflektanssia, kuten luvussa 4.1 kerrottiin. Reflektanssimosaiikin laskennan ensimmäisenä vaiheena on saada yhteys harmaasävyarvojen ja reflektanssin välille eli määrittää absoluuttisen kalibroinnin parametrit a_{abs} ja b_{abs} kaavassa 7. Tämän jälkeen on vielä tehtävä reflektanssiin korjaukset, jotka johtuvat mittausteoriasta eli käytännössä siitä, että kohteet ovat kirkkaampia myötä- kuin vastavalossa sekä muus-

ta valaistusolosuhteiden vaihtelusta eli käytännössä pilvisyydestä. Tästä vaiheesta käytetään tässä yhteydessä nimitystä suhteellinen kalibrointi.

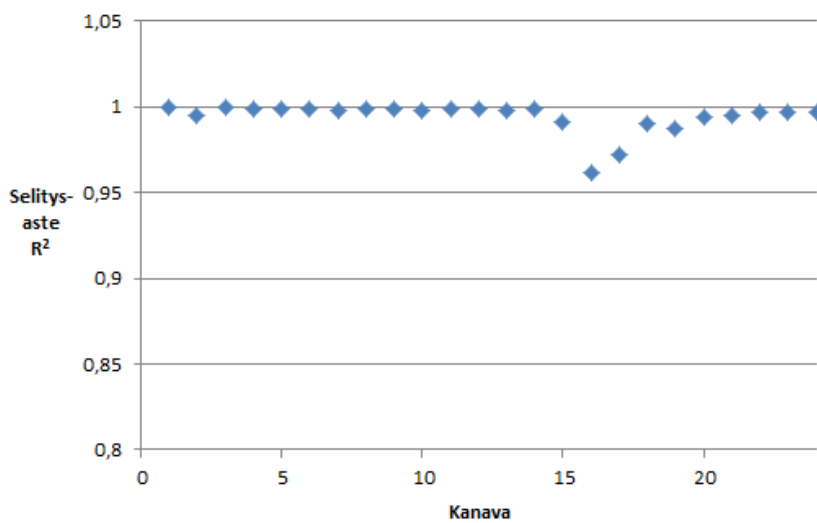

5.5.1 Absoluuttisen radiometrisen kalibroinnin määrittäminen

Absoluuttisen kalibroinnin määrittämiseksi empiirinen viiva -menetelmällä maastoon oli levitetty tasaisia referenssikohteita, joiden reflektanssi mitattiin Avantes-kenttäspektrometrillä. Maastoon tuotujen referenssikohteiden lisäksi mitattiin myös mitta-uspaikalla soran ja nurmikon spektrit (Kuva 26).



Kuva 26 Vasemmalla mitatut referenssikohteet ja oikealla niiden spektrit. Referenssipaneeleita (P10, P25) ja nurmikkoa (field) on mitattu kolme kertaa.

Kuvan, jossa mitatut referenssikohteet näkyivät, jokaiselta kanavalta kerättiin tieto mitattujen kohteiden harmaasävyarvoista. Näihin mittauksiin sovitettiin suora lineaariseen regressioon perustuen (kaava 6), jotta termit a_{abs} ja b_{abs} saatiin ratkaistua. Soran spektriä ei käytetty ollenkaan, sillä sen harmaasävyarvojen hajonta kuvilla oli suurempaa kuin muilla kohteilla.



Kuva 27 Ylhäällä absoluuttisen kalibroinnin määrittäminen kanavalle 1 ja alhaalla lineaarisen regression onnistumista kuvaavat selitysasteet jokaiselle kanavalle.

Taulukko 7 Absoluuttisen kalibroinnin parametrit ja niiden keskihajonnat kanavittain.


Kanava	Aallonpituus nm	Absoluuttisen kalibroinnin parametrit		Parametrien keskihajonta	
		a	b	a	b
1	516,5	62724,97	604,1628	1605,324	199,3985
2	522,3	47906,41	1389,501	1442,155	179,5794
3	525,9	80095,23	850,3853	2059,041	257,7476
4	526,8	47503,45	459,5879	986,5588	123,6625
5	538,2	85635,43	860,4899	2103,359	265,4701
6	539,2	54183,49	553,3377	1467,116	185,4181
7	548,9	57066,27	538,9761	1507,553	190,8991
8	550,6	80358,44	864,0542	2089,346	264,1535
9	561,6	46176,13	212,8243	1145,036	143,9438
10	568,3	66572,84	779,164	1735,655	214,7934

11	592,2	62707,17	604,321	4329,734	519,6831
12	607,5	71640,2	406,291	4422	523,8855
13	613,4	70763,93	562,9163	3419,316	402,6476
14	626,3	71892,33	433,3313	4253,642	494,5751
15	699	22947,67	713,2932	2247,341	267,5395
16	699,9	50971,37	-46,722	5435,64	671,0933
17	706,2	47356,19	684,6168	5376,008	710,2423
18	712	30602,67	887,3059	2891,225	406,5641
19	712,4	43896,86	953,111	4298,636	618,1045
20	725,8	27581,14	1362,458	1497,911	259,753
21	755,6	34407,17	2238,97	1230,958	272,2219
22	772,8	29432,62	1859,343	1094,004	249,7227
23	793,8	24308,89	1692,054	963,8603	224,5498
24	813,9	20178,39	1571,68	732,5438	173,262

Kuva 27 on esitetty kanavan absoluuttisen kalibroinnin ratkaisu kanavalle 1 (aallonpituus 516,5nm): a_{abs} 62725, b_{abs} : 604,16. Ratkaisu onnistui hyvin, sillä selitysaste R^2 oli 0,9954. Määrittäminen onnistui myös kokonaisuudessaan hyvin, sillä useimmilla kanavilla lineaarisen regression selitysasteet olivat jopa yli 0,99 ja huonoimmillaankin 0,96. Taulukko 7 on esitetty kaikkien kanavien ratkaistut absoluuttiset kalibrointiparametrit ja niiden keskihajonnat.

5.5.2 Suhteellisen radiometrisen kalibroinnin määrittäminen

Epätasaisista valaistusolosuhteista johtuvia häiriötä poistamista tutkittiin muutamalla luvussa 4.1.5 esitetyllä menetelmällä. Ensimmäinen tutkittiin Hakalan (2013) esittelemää maasta kerätyn irradianssidatan käyttöön sekä kuvien keskiarvoon perustuvaa menetelmää. Irradianssimittauksiin perustuvaa menetelmää varten kerättyä irradianssidataa oli tallennettu sekunnin välein ja 350-2500 nm:n alueelta yhden nanometrin välein. Tämä data oli muunnettava interpoloimalla sellaiseen muotoon, jossa aallonpituudet vastaavat kuvauksessa käytettäviä sekä yhdistettävä irradianssimittausajankohdat kuvien ottohetkiin aikaleimojen perusteella. Kuva 28 on esitetty kaikkien 24 kanavan mitatut suhteelliset irradianssit, $C_j(\lambda)$ (kaava 10), kullakin kuvanottohetkellä.



Kuva 28 Maasta kerätyt irradianssimittaukset kuvauslennon aikana

Kuva 28 matalat arvot viittaavat vähäiseen valaistukseen (pilvisuus) määrään ja korkeat arvot aurinkoiseen säähän. Lyhimmillä kerätyillä aallonpituusalueilla mittaus on saturoitunut muutamana ajanhetkenä. Tällaisia mittauksia ei voida pitää luotettavana eikä niitä voida käyttää suhteellisen kalibroinnin määrittämiseen.




Kuva 29 Vasemmalla korjaamaton ortokuva, keskellä maasta kerättyjen irradianssimittausten perusteella ja oikealla keskiarvomenetelmällä korjattu eteläisempi ortokuvablokki spektraalisesti korjatulla kanavalla 12 (aallonpituus 607,5 nm)

Kuva 29 on esitetty suhteellisesti korjaamaton, irradianssimittausten perusteella sekä keskiarvomenetelmällä korjatut ortokuvablokit kanavalta 12 ($L_0=607,5$ nm). Korjaamattomassa kuvassa näkyy jonkin verran eri valaistusoloista johtuvia kuvien eroja vierekkäisten kuvien välillä. Irradianssimittausten perusteella korjatussa kuvassa jonojen väliset erot tulevat erityisen hyvin näkyviin eikä menetelmä näin ollen näytä soveltuvan tämän blokin radio-

metriseen korjaamiseen. Irradianssimittaukset on tehty pohjoisemman blokin alueella 6-9 km:n etäisyydellä eteläisestä blokista, joten todennäköisesti irradianssimittausten sopimattomuus johtuu siitä, että valaistusolosuhteet ovat olleet erilaisia mittaus- ja kuvanottoaikalla. Keskiarvomenetelmä korjaa hyvin erityisesti tummaksi jääneitä metsäalueita vaa- leammiksi mutta silloin, kun kuvalla on sekä kasvillisuutta että rakennettua ympäristöä tällainen menetelmä ei toimi kovin hyvin johtuen kohteiden erilaisista heijastusominaisuuksista.

Toisena suhteellisen kalibroinnin menetelmänä tutkittiin Honkavaaran ym. (2013) kehittälemää radiometrasta blokkitasoitusta. Tässä tutkimuksessa kyseistä menetelmää käytettiin siten, että toista suhteellisen korjauksen parametria $b_{rel,j}$ (kaavassa 7) ei käytetty ollenkaan yliparametrisoinnin välttämiseksi. Menetelmä perustuu radiometrinen liitospisteiden käyttöön, joiden välisiä eroja tutkimalla saadaan ratkaistua kuvakohtaiset suhteelliset parametrit $a_{rel,j}$ sekä brdf-parametrit a ja b (kaava 9). Tärkein havaintoryhmä on radiometrinen liitospisteiden keskimääräiset sävyarvot. Tasoituksen rajoittamiseksi myös kuvakohtainen suhteellinen korjauskerroin $a_{rel,j}$ pidettiin tasoituksessa painotettuna havaintona. Koska koko kuvan alueelle määritetään yksi parametri, kuvat, joilla kohde on osittain pilvien varjossa, ovat menetelmän kannalta vaikeita. Tämän takia blokista poistettiin n. 20 tällaista puolipilvistä kuvaa. Tästä huolimatta blokkiin ei tullut suuria aukkoja, sillä sekä pituus- että sivupeittoprosentit olivat n. 70% mutta lähes kaikki pilven varjossa ortokuvalla olleet alueet saatiin poistettua (Kuva 30).



Kuva 30 Kanavista 23, 12 ja 2 koostetut suhteellisesti korjaamattomat väärävärivablokit; vasemmalla kaikki alkuperäiset kuvat ovat mukana, oikealla puolipilviset kuvat on poistettu.

Radiometrisessä blokkitasoituksessa havainnoille annettavien painojen merkitys on suuri tasoituksen onnistumiseksi. Painot on valittava niin, että tasoitettavat parametrit voivat liikkua sopivasti. Lisäksi huomattiin, että painojen valintaan vaikuttaa kuvattu kohde, sillä aiemmissa tutkimuksissa (mm. Honkavaara ym 2013) pelloille käyttämät painot eivät so-



veltuneet suoraan metsäisen blokin painotukseen. Tämä johtuu siitä, että tasaisilla kohteilla, kuten pelloilla saman kohteen harmaasävyarvo eri kuvilla vaihtelee vähemmän kuin epätasaisemilla kohteilla, kuten metsällä. Lisäksi BRDF-parametreja määrittäessä huomattiin, että koko alkuperäistä kuva-alaa käytettäessä näiden parametrien määrittäminen ei onnistunut toivotulla tavalla, mikä johtui lentokoneen kuvausaukon aiheuttamista tummista reunoista sekä sen aiheuttamasta varjostuksesta kuvien reunoille. Tämän takia käytettävää kuva-alaa pienennettiin, siten että vain kuvan keskiosaa käytettiin parametrien määrittämiseen. Tämä oli mahdollista blokin hyvien peittoprosenttien takia, jolloin vain kuvan keskiosaa käytettiin ortokuvan muodostamisessa sekä radiometrisen blokkitasoituksen laskennassa. Sopivien painojen ja kuva-alan pienentämisen jälkeen tasoitus tuotti johdonmukaisia tuloksia, Taulukko 8 on esitetty nämä radiometrisessä blokkitasoituksessa käytetyt parametrit sekä havaintojen keskihajonnat. Painoyksikön keskihajonta laskettiin jokaiselle kanavalle erikseen kaavalla:

$$\sigma_0 = \sigma_{DN} * (a_{abs} * \rho_{kesk} + b_{abs}), \quad (11)$$

jossa σ_{DN} on harmaasävyarvojen arvioitu keskihajonta ja keskimääräinen reflektanssi (ρ_{kesk}) on metsäkohteessa näkyvän valon kanaville 0,05 ja lähi-infra alueen kanaville 0,3.


Taulukko 8 Radiometrisessä blokkitasoituksessa käytetyt parametrit: parametrien määrittämiseen käytetty kuva-ala, havaintoina käytettyjen liitospisteiden ikkunakoko, sekä tasoituksessa painoina käytetyt suhteellisen korjausparametrien ja harmaasävyarvojen keskihajonta.

Käytetty kuva-ala	450*450 pikseliä
Liitospisteiden ikkunakoko	30 pikseliä
Suhteellisen korjausparametrien keskihajonta σ_{arel}	0,05
Harmaasävyarvojen keskihajonta σ_{DN}	0,1



Kuva 31 Vasemmalla suhteellisesti korjaamattoman (ei korjausta) ja brdf-rela -korjatun blokin homogeenisuutta kuvaavat variaatiokertoimet ja oikealla viimeksi mainittujen perusteella muodostettu väärävärivablockki (vrt. Kuva 30)

Kuva 31 on esitetty suhteellisesti korjaamattoman sekä suhteellisesti ja brdf –korjatun kunkin kanavan blokin homogeenisuutta kuvaavat radiometristen liitospisteiden variaatiokertoimet eli keskiarvon ja keskihajonnan suhteet. Variaatiokertoimien perusteella blokin homogeenisuus parani korjauksen vaikutuksesta hieman useimmilla kanavilla. Variaatiokertoimet vaihtelevat 0,1:n ja 0,2 välillä, lukuun ottamatta kanavaa 2 (522,3 nm), jossa variaatiokertoimet olivat noin 0,4 sekä korjatulle korjaamattomalle blokille. Poikkeava luku saattaa johtua siitä, että tämä kanava oli yksi huonolaatuisimmista kanavista SNR-arvon perusteella (Kuva 16). Variaatiokertoimien lisäksi korjauksen onnistumista voi tarkkailla vertailemalla eri menetelmillä ratkottuja suhteellisia korjauskertoimia (Kuva 32). Huomataan, että variaatiokertoimet ovat huomattavasti suurempia kuin aikaisemmissa tutkimuksissa peltoalueilla saadut tulokset (Honkavaara ym. 2013). Syynä tähän on kohteesta johtuva hajonta.



Kuva 32 Eri menetelmillä määritetyt suhteelliset korjauskertoimet a_{rel} esitettynä kuvittain.


Kuva 32 nähdään, että ainoastaan suhteellisen korjauksen (rela) sekä suhteellisen ja brdf-korjauksen (brdfrela) avulla ratkotut parametrit ovat samankaltaisia. Myös keskiarvomenetelmän (keskiarvo) avulla lasketuissa parametrissa on huomattavissa jonkin verran samankaltaisuutta edellisiin nähden mutta maasta kerättyjen irradianssihavaintojen (irrad) perusteella määritetyt parametrit eroavat huomattavasti muista. Suhteellisesti korjaamattomassa blokissa jokaisen kuvan a_{rel} -arvo on 1 mutta sitä ei ole esitetty kuvassa luettavuuden parantamiseksi. Näistä seuraavan vaiheen analysointiin otettiin mukaan suhteellisesti korjaamaton (ei_korj), sekä suhteellisesti korjatut vaihtoehdot: ”rela” ja ”brdfrela”.

5.6 Koealojen puiden spektrit ja niiden vastaavuus maastohavaintoihin

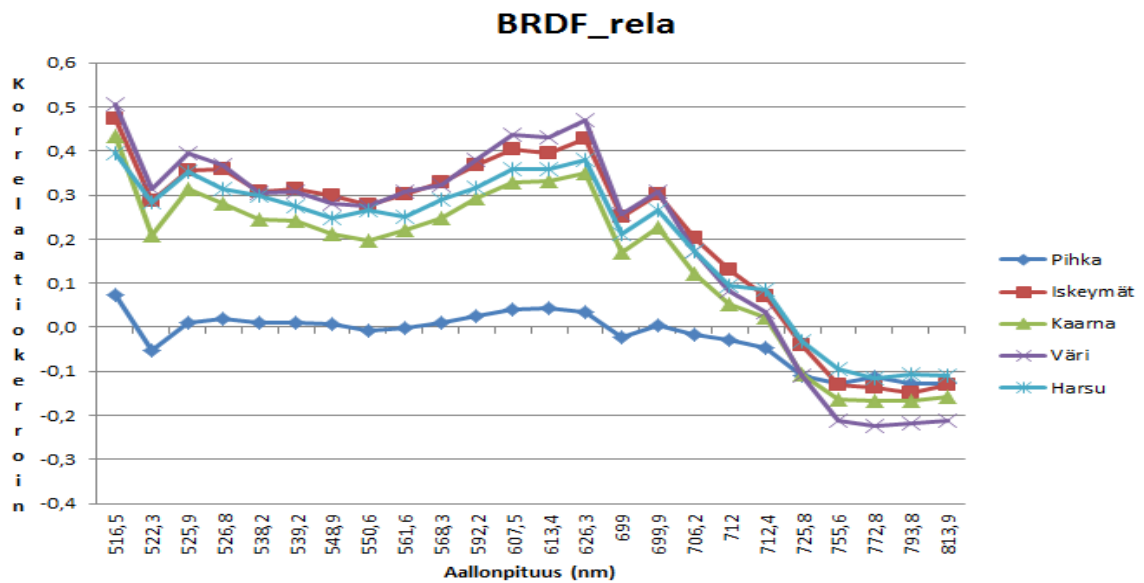
Jokaiselle koealan puulle laskettiin spektrit luvussa 4.3 esitettyllä menetelmällä. Spektrit laskettiin radiometrisesti suhteellisesti korjaamattomalle, relaatiivisesti korjatulle ja sekä relaatiivisesti, että brdf-korjatulle reflektanssikuvulle. Koealoilta oli kerätty tiedot kaikista, myös hyvin pienestä puista. Tällaiset hyvin pienet eivät näkyneet FPI-kuvilla, joten niiden spektrit poistettiin jatkoanalyseista. Poistettaviksi puiksi valittiin kaikki alle 10 cm:n rinnankorkeuslähpimitaltaan olleet puut sekä puut, joista mitattu signaali oli heikko luultavasti


varjostuksesta johtuen. Varjossa olleet puut poistettiin laskemalla jokaisen kanavan reflektanssin keskiarvo ja poistamalla alle 0,02:n arvolla olleet havainnot.

Koepuiden spektreja verrattiin maastohavaintoihin ensin laskemalla jokaisen kanavan ja kultakin kuuselta (250 kpl) kerätyn terveysparametrin (pihka, iskeymät, kaarna, väri ja harsuuntuneisuus, ks. tarkemmin luku 3.2) välille Pearsonin korrelaatiokerroimet (Kuva 34). Pearsonin korrelaatiokerroin on tarkoitettu kuvaamaan lähinnä kahden välimatka- tai suhteasteikollisen parametrin lineaarista korrelaatiota. Tässä tapauksessa terveysparametrit oli kuitenkin luokiteltu järjestysasteikolla kolmeen tai neljään luokkaan. Järjestysasteikollisille parametreille on olemassa omia korrelaatioita kuvaavia kertoimia, kuten Spearmanin järjestyskorrelaatiokerroin, joka vastaa Pearsonin korrelaatiokerrointa laskettuna muuttujien järjestyslukuilla. Tässä tapauksessa Spearmanin järjestyskorrelaatiokerroin ei tuota Pearsonin korrelaatiokerrointa parempaa tulosta, sillä värien järjestysluvut ovat edelleen vain kolmessa luokassa ja reflektanssien järjestyslukujakin on edelleen lähes 250, vain asteikko on muuttunut (Kuva 33).



Kuva 33 Vasemmalla kanavan 1 reflektanssin ja terveysparametrin, väri, välinen yhteys sekä oikealla vastaava kuva reflektanssin ja värin järjestyslukuilla esitettynä. Värin 3 kuusia ei ollut tutkimusalueella lainakaan.






Kuva 34 Maastosta havaittujen terveystietojen ja jokaisen kanavan reflektanssin väliset Pearsonin korrelaatiokertoimet (R) laskettuna kolmella eri suhteellisen kalibroinnin vaihtoehdolla.

Pihkaantuneisuutta lukuun ottamatta terveystiedot korreloivat positiivisesti näkyvän valon alueella ja negatiivisesti lähi-infran alueella, mikä oli odotettu tulos (Kuva 34). Relatiivisesti korjatuilla kuvilla (brdfrela, rela) korrelaatio ovat jonkin verran voimakkaampaa kuin korjaamattomalla kuvalla (ei_korj). Näkyvän valon alueella, erityisesti vihreän aallonpituuksilla (530-580 nm), brdfrela –korjatussa tapauksessa korrelaatiot ovat hieman suurempia verrattuna ainoastaan relatiivisesti korjattuun mutta lähi-infran alueella tilanne on päinvastoin. Terveystiedoista parhaiten korreloivat väri, iskeymät ja harsuuntuneisuus

ja kertoimen arvo on parhaimmillaan n. 0,5 kanavilla, joiden aallonpituudet ovat 516,5 ja 626,3 nm. Väriin odotettiin korreloivan reflektanssin kanssa parhaiten, sillä se on suoraan havaittavissa ilmasta toisin kuin kuusten rungoilta havaittavat parametrit. Terveysparametrit korreloivat myös keskenään, sillä puun sairastuessa esiintyy usein kaikkien parametrien kuvaamia oireita.

Yksittäisten kanavien reflektansseja paremmin kasvillisuushavaintojen kanssa korreloivat usein kasvillisuusindeksit, kuten NDVI (ks. luku 2.4.2). NDVI laskettiin tässä usean kanavan avulla siten, että sekä lähi-infran että punaisen alueen kanavista otettiin keskiarvo kohinan vähentämiseksi. NDVI:n ja terveysparametrien Pearsonin korrelaatiokertoimet laskettiin kahdelle eri tavoin suhteellisesti korjatulle sekä korjaamattomalle aineistolle (Kuva 35).



Kuva 35 Terveysparametrien ja NDVI:n väliset Pearsonin korrelaatiokertoimet eri tavoin suhteellisesti korjatuille blokeille.

Radiometrian suhteellisesta korjaamisesta oli hyötyä, sillä korjaamattomalla kuvalla NDVI:n korrelaatio oli heikoin jokaisella terveysparametrilla. Väriin suhteen rela- ja brdfrela -vaihtoehdot korreloivat yhtä hyvin (-0,75) ja toisella latvoissa näkyvissä terveysparametrissa, harsuuntuneisuudessa brdfrela korreloi hieman rela -vaihtoehtoa paremmin, kun taas rungolla näkyvillä parametreilla tilanne on päinvastoin. Tämän takia analyysin seuraavat vaiheet päätettiin tehdä teoriainkin mukaan parhaimmalla sekä brdf- korjauksen että suhteellisen korjauksen sisältävällä vaihtoehdolla.


Edellä NDVI oli siis laskettu käyttämällä useaa punaisen ja lähi-infran alueen kanavaa. NDVI laskettiin myös yksittäisten kanavien avulla käyttämällä neljää lähi-infra- ja kymmentä näkyvän valon kanavaa eli laskettavia yhdistelmiä oli yhteensä 40. Terveysparametrien ja näiden yksittäisten parametrien Pearsonin korrelaatiokertoimet laskettiin, jotta voitiin tutkia, olivatko jotkin kanavat erityisen informatiivisia kirjanpainajatuhojenkartoittamiseksi (Taulukko 9).

Taulukko 9 Kymmenen parasta ja viisi heikoiten korrelointua kanavayhdistelmää, kun vertailtiin näiden kanavien avulla laskettua NDVI:tä ja terveysparametrien Pearsinin korrelaatiokerroimia

NDVI:n laskennassa käytetty kanava		Terveysparametrin ja NDVI:n välinen Pearsonin korrelaatiokerroin				
Lähi-infra	Näkyvä valo	Harsu	Iskeymät	Kaarna	Pihka	Väri
23	8	-0,2895	-0,3819	-0,187	-0,223	-0,5454
23	10	-0,2462	-0,3887	-0,2266	-0,2113	-0,5318
22	10	-0,2794	-0,3711	-0,2282	-0,1606	-0,5438
23	14	-0,2327	-0,3766	-0,2188	-0,1922	-0,562
23	11	-0,2235	-0,3833	-0,2291	-0,2018	-0,5383
24	14	-0,2614	-0,3479	-0,2211	-0,197	-0,5461
24	8	-0,3149	-0,3349	-0,1832	-0,2178	-0,512
22	8	-0,3144	-0,3503	-0,181	-0,1637	-0,5385
24	1	-0,2669	-0,3454	-0,2235	-0,208	-0,5001
24	11	-0,2504	-0,3459	-0,2289	-0,2028	-0,515
21	4	-0,0646	-0,2051	-0,1108	-0,1206	-0,3199
21	15	-0,0745	-0,2043	-0,0745	-0,1009	-0,3529
21	19	-0,1105	-0,1634	-0,089	-0,1302	-0,3135
21	7	-0,0538	-0,2149	-0,0959	-0,1262	-0,3105
21	9	-0,0275	-0,1814	-0,074	-0,1266	-0,2844

Sillä asialla, mitä kanavia käytettiin NDVI:n laskennassa, oli selvästi merkitystä, sillä esimerkiksi terveysparametrin väri ja NDVI:n välinen Pearsonin korrelaatiokerroin oli parhaimmillaan -0,55 ja heikoimmillaan -0,28. Parhaimmillaan korrelaatio on, kun lähi-infran alueen kanavana on käytetty kanavia 23 (793,3 nm) ja 24 (813,9 nm) ja näkyvän valon alueelta kanavia 8 (550,6 nm) ja 10 (568,3 nm). Heikoimmillaan korrelaatio on, kun lähi-infra-alueen kanavana on käytetty 755,6 nm vastaavaa kanavaa 21 (Taulukko 9).

Koska terveysparametreista väri odotetustikin korreloi parhaiten mitattujen reflektanssien sekä siitä johdetun NDVI:n perusteella, valittiin tässä tutkimuksessa se kuvaamaan puun tervettä, kun koelajien ulkopuolisten puiden terveyttä alettiin kartoittaa. Tätä varten laskettiin jokaista väriä vastaavien puiden keskiarvospektrit (Kuva 36).




Kuva 36 Terveysparametrin väri mukaan lasketut kuusten keskiarvospektrit. Kuvaajaan on piirretty virhepalkit keskivirheen eli keskihajonnan ja otoskoon neliöjuuren suhteen perusteella.

Kuolleiden kuusten (väri 4) spektri eroaa erityisesti lähi-infrapun alueella selvästi muista spektreistä. Täysin terveiden väriltään vihreiden (1) ja kellertävien (2) spektrit eroavat vähemmän toisistaan mutta näkyvän valon alueella värin 2 kuusten reflektanssi on hieman värin 1 kuusia voimakkaampaa ja lähi-infran alueella vähäisempää. Värin 1 kuusia oli aineistossa 163, värin 4 kuusia 48, värin 2 kuusia vain 14 ja värin 3 kuusia ei ollenkaan. Eriyisesti värin 2 kuusten määrä oli niin pieni, ettei niiden avulla lasketusta keskiarvospektriä voinut pitää varmasti luotettavana. Saatu tulos kuitenkin vastaa myös sairastuneiden eli värin 2 osalta Meddensin ym. (2011) esittämää tulosta kaarnakuoriaisten aiheuttamille kuusten spektrien muutoksille, joten värin 2 puita käytettiin kuvaamaan sairastuneita puita luokiteltaessa tuhoalueen muita puita.


5.7 Puiden luokittelu ja tuhokartat

Tutkimusalueen jokainen puu oli tärkeä tunnistaa, jotta niiden spektrit voitiin laskea ja muodostaa luokittelun avulla tuhokartat. Puiden keskipisteet etsittiin luvussa 4.2 esitellyllä, luokitteluun perustuvalla, menetelmällä. Keskipisteiden etsimistä kokeiltiin myös eri aineistosta tuotettujen pintamallien avulla SocetGXP:n automaattisilla puiden tunnistusalgoritmeilla. RGB- ja varsinkaan FPI –pintamallista puiden tunnistus ei onnistunut hyvin. Sen sijaan MML:n avoimesta laserkeilausaineistosta tuotetusta pintamallista puiden tunnistus sujui visuaalisesti arvioituna kohtuullisen hyvin (Kuva 37).



Kuva 37 Vasemalla SocetGXP:llä NGATE:lla RGB-kuvista lasketusta pintamallista löydettyjä puita ja oikealla löydetyt puut laserkeilausaineistosta tehdyltä pintamallilta.


Keskipisteiden etsintä päätettiin kuitenkin tehdä pelkästään FPI-kuvien luokitteluun perustuvalla menetelmällä, sillä tällöin ei ole vaaraa siitä, että löydetyt keskipisteet eivät osuisikaan kuvilla latvojen päälle johtuen mahdollisista geometrisista epätarkkuuksista eri aineistojen välillä. Keskipisteiden etsimistä varten tutkimusalue rajattiin tarkemmin koskemaan vain metsiä (Kuva 38). Visuaalisesti arvioituna puiden latvojen etsintä onnistui tällä menetelmällä hyvin (Kuva 38).



Kuva 38 Vasemmalla tutkimusalue rajattuna katkoviivalla alueen väärävärivuvan päällä. Oikealla ylhäällä yksityiskohta väärävärivuvasta ja alhaalla saman alueen puuntunnistusalgoritmin löytämät puiden keskipisteet merkittynä punaisilla pisteillä menetelmän käyttämän luokittelukuvan päällä.

Erityisen hyvin löytyivät selvästi erillään olevat suuret puut, jotka eivät muodostaneet yhtenäistä latvustoa, eli käytännössä havupuut. Sen sijaan lehtipuiden yhtenäisemmän latvuston takia, useammalle puulle saattoi menetelmällä löytyä vain yksi keskipiste. Tämä ei kuitenkaan tässä tapauksessa ollut merkittävää, sillä tutkimuksessa oltiin ensisijaisesti kiinnostuneita kuusista. Puiden keskipisteiden löytymisen jälkeen jokaiselle puulle laskettiin spektri samaan tapaan kuin koelan puille eli laskemalla jokaisella kanavalla reflektanssien keskiarvo 3*3 pikselin kokoisen ikkunan alueelta.

Puiden luokitteluksi eri sairausasteen puihin tehtiin ohjatun luokittelun avulla käyttämällä opetusaineistona koelajien puiden spektrejä siten, että värin 1 kuuset kuvaavat terveitä havupuuta (käytännössä kuusta, sillä alueella ei ollut juurikaan mäntyjä), värin 2 kuuset kirjanpainajien sairastuttamia kuusia ja värin 4 kuuset kirjanpainajien jo tappamia kuusia. Metsässä oli havupuiden lisäksi myös lehtipuita, joiden spektri eroaa huomattavasti havupuiden spektristä, joten lehtipuut muodostivat luokittelun neljännen luokan (Kuva 39).



Kuva 39 Ohjatun luokittelun luokkien opetusaineiston keskiarvospektrit

Ohjattu luokittelu tehtiin neljän eri luokittelualgoritmin avulla. Käytetyt algoritmit ovat pienimmän etäisyyden luokittelija, suurimman uskottavuuden luokittelija, Spectral Angle Mapper (SAM) ja Spectral Correlation Mapper (SCM), joiden periaatteet on esitetty luvussa 2.4.3. Luokittelun onnistumista kuvaavat virhematriisit ja kappa-arvot (kaava 11) laskettiin käyttämällä opetusaineistoa, sillä maastohavaintoja oli niin vähän, ettei aineiston jakaminen kahteen osaan ollut järkevää eikä luokitteluun käytetyllä Erdas Imagine -ohjelma kyennyt ristiinvaldointiin ilman huomattavaa käsityötä (Taulukko 10).

Taulukko 10 Eri luokittelijoiden virhematriisit, oikeinluokitusprosentit ja kappa-arvot

Pienimmän et. luok.	Kappa: 0,3868				Oikeinluokitus-%
	Lehtipuut	Terve 1	Sairas 2	Kuollut 4	
Lehtipuut	24	14	1	0	92,3
Terve 1	2	66	3	1	40,5
Sairas 2	0	32	8	4	57,1
Kuollut 4	0	51	2	43	89,6

Suurimman usk. luok.	Kappa: 0,7913				Oikeinluokitus-%
	Lehtipuut	Terve 1	Sairas 2	Kuollut 4	
Lehtipuut	25	3	0	0	96,2
Terve 1	1	152	12	1	93,3
Sairas 2	0	0	0	0	0,0
Kuollut 4	0	8	2	47	97,9


SCM	Kappa: 0,4767				Oikeinluokitus-%
	Lehtipuut	Terve 1	Sairas 2	Kuollut 4	
Lehtipuut	25	23	0	0	96,2
Terve 1	1	90	4	5	55,2
Sairas 2	0	37	9	4	64,3
Kuollut 4	0	13	1	39	81,3

SAM	Kappa: 0,4095				Oikeinluokitus-%
	Lehtipuut	Terve 1	Sairas 2	Kuollut 4	
Lehtipuut	24	28	0	0	92,3
Terve 1	2	77	4	2	47,2
Sairas 2	0	49	9	10	64,3
Kuollut 4	0	9	1	36	75,0

Kaikille luokittelijoiden tuloksille yhteistä on se, että lehtipuiden ja kuolleiden kuusten oikeinluokitusprosentit ovat paremmat kuin terveiden ja sairastuneiden kuusten, mikä oli odotettavaa, sillä terveiden ja sairastuneiden kuusten spektrit muistuttivat niin paljon toisiinsa. Koko luokittelun onnistumista kuvaava kappa-arvo on paras suurimman uskottavuuden luokittelijalla ja heikoin pienimmän etäisyyden luokittelijalla. Suurimman uskottavuuden luokittelija ei kuitenkaan ole luokitellut yhtäkään puuta luokkaan sairastuneena, mikä oli koko tutkimuksen kannalta tärkein luokka. Se, ettei suurimman uskottavuuden luokittelija luokitellut yhtään sairasta puuta oikein, johtuu siitä, että algoritmi perustuu todennäköisyyslaskentaan sekä itse opetusaineistosta, sillä kahden spektrisesti hyvin lähellä olevan luokan, terve ja sairastuneena, lukumäärissä oli valtava ero terveiden puujen eduksi (163 tervettä, 14 sairastunutta), jolloin kaikki tämänkaltaiset spektrit ovat todennäköisemmin isoon luokkaan kuuluvia. Tämän takia parhaana luokittelijana tällaiselle datalle on pidettävä SCM-

algoritmia, jonka kappa-arvo on toiseksi suurin (0,47) ja joka on kehitetty nimenomaan hyperspektridatan luokitteluun. SCM-algoritmilla oikeinluokitusprosentti sairaille puille on algoritmien paras 64,3 %. SCM-algoritmi luokitteli erityisen hyvin kuolleet puut (81,3 %) ja lehtipuut (96,2 %). Sen sijaan terveitä puita luokiteltiin 55,2 %:sti oikein, sillä luokan puita luokittui jonkin verran myös sairastuneiden ja lehtipuiden luokkaan.

Luokittelun tulosten visuaalista esittämistä varten muodostettiin tuhkakartat merkitsemällä jokainen puu sen luokan mukaan valitulla värillä.



Kuva 40 SCM-luokittelijan avulla muodotettua tuhkakarttaa. Ylempänä puut esitetty väärävärikuvan ja lähi-infra-alueen kanavan päällä ja alhaalla isomman alueen tuhkakarttaa.

Luokittelun tulosta voi yrittää arvioida myös visuaalisesti, kun vertaa väärävärikuvaa ja luokittelutulosta (Kuva 40). Tutkimalla suuremman alueen tuhkakarttaa saa nopeasti käsityksen siitä, mitkä alueet ovat kirjanpajan pahimmin vaivaamia.

6 Johtopäätökset

Työn tavoitteena oli selvittää, miten FPI-kameran keräämää aineistoa voidaan käyttää kirjanpainajatuhojen kartoittamisessa. Tässä työssä esitetty prosessi ja tulokset osoittavat, että kirjanpainajatuhoja on mahdollista kartoittaa FPI-kameran avulla. Varsinkin kuolleet kuuset pystytään luokittelemaan muiden puiden joukosta luotettavasti, mikä onnistuisi myös RGB-kuvilta. Kirjanpainajan sairastuttamien kuusien erottaminen terveistä puista on vaikeampaa, sille niiden spektrit ovat tutkitulla aallonpituusalueella lähellä toisiaan. Tutkitulla alueella oli kuvausaikaan kuitenkin ainoastaan terveitä (väri 1), kirjanpainajien lievästi vaivaamia (väri 2) ja täysin kuolleita (väri 4) eikä kirjanpainajien pahemmin vaivaamia mutta vielä elossa olevia kuusia (väri 3) ollut lainkaan. Oletettavasti tällaisten puiden (väri 3) spektri olisi eronnut enemmän terveen puun spektristä, jolloin niiden luokittelu olisi onnistunut paremmin. Vaikka tässä työssä sairastuneiden kuusia ei pystytäkään täydellä varmuudella tunnistamaan, oikeinluokitusprosentti parhaimmillaan 64 %, työssä esitettyjen tuhokarttojen avulla saadaan kuitenkin nopeasti kuva siitä, millä alueilla riski kirjanpainajatuhoille on erityisen suuri, jotta voidaan aloittaa toimet niiden leviämisen estämiseksi. Parhaimmillaan valmistettujen tuhokarttojen avulla voitaisiin antaa paikannuslaitteet omaavalle hakkuukoneelle suoraan tiedot riskipuista, jotka se kävisi poistamassa.

Ennen tuhokarttojen valmistumista, tarvitaan kuitenkin FPI-kuvien analysointia ja prosessointia, jotka sisältävät useita vaiheita, joista joidenkin tekeminen on aikaa vievää. Tätä prosessointia olisikin saatava kehitettyä tarkemmaksi ja nopeammaksi. Seuraavassa esitetään, mitkä prosessoinnin osat vaativat eniten kehittämistä ja miten niitä voitaisiin kehittää.

FPI-kuvien esiprosessoinnissa korjataan kuvien spektraalisia ja radiometrisiä vääristymiä sekä sovitetaan kanavat päällekkäin. Nämä vaiheet olisi hyvä yhdistää yhdeksi prosessiksi, sillä erikseen tehtynä ne vievät jonkin verran aikaa. Lisäksi spektraalisen vääristymän korjauksen vuoksi kerättyjen kanavien lukumäärä pienenee ja alun perin kattavaan spektriin voi tulla aukkoja, kuten tässä kävi 630-690 nm:n alueella. Ennen kerättävien aallonpituuksien valintaa tulisikin huomioida mitä aallonpituuksia on käytössä spektraalisen vääristymän korjauksen jälkeen tai kehittää korjauksen tekemiseen muita menetelmiä.

Kuvablokkien orientointien ratkaiseminen vaati tällä aineistolla tukipisteiden manuaalista mittaamista valmiiksi oikaistuilta ortokuvilta, sillä maastossa tukipisteitä ei ollut mitattu. Lisäksi orientointien ratkaisua ei voinut perustaa ainoastaan lennon aikana kerättyjen paikannustietojen varaan, sillä ne eivät olleet tarpeeksi tarkkoja. Tätä prosessointia voisikin automatisoida parantamalla lentokoneen paikannusjärjestelmää tai kehittämällä muita menetelmiä orientointien ratkaisuun, kuten hyödyntää olemassa olevia tarkkoja pintamalleja soveltamalla niitä nykyfotogrammetrian avulla saataviin yksityiskohtaisiin pintamalleihin.

Valaistusolosuhteiden vaihtelusta johtuvat blokin radiometriset korjaukset ovat vaativia toteuttaa ja vaativat vielä kehittämistä, erityisesti puolipilvisten kuvien huomioiminen, sillä niiden korjaaminen ei vielä kehitetyillä menetelmillä ole mahdollista. Tässä työssä ongelma vältettiin poistamalla puolipilviset kuvat aineistosta mutta, mikäli tällaisia kuvia on runsaasti, tämä ei ole mahdollista. Myös muiden kuin pilvien aiheuttamien varjojen vaiku-

tukset kuvilta olisi hyvä saada eliminoitua. Lisätutkimusta kaipaa myös se, että millainen radiometrisessä korjauksessa käytettävä brdf-malli on optimaalinen metsäisille kuvablokkeille. Tässä työssä käytetyn mallin on todettu soveltuvan hyvin peltoalueiden korjaukseen, mutta ilman brdf-korjausta olleen blokin maastohavaintojen ja spektriaineiston korrelaatiot eivät tässä metsäisen blokin tapauksessa juuri eronneet brdf-korjauksen sisältäneestä vaihtoehdosta, vaikka teorian ja aiempien peltoalueilla tehtyjen tulosten perusteella (Honkavaara ym. 2013) näin voisi odottaa. Toisaalta mosaiikeissa käytettiin vain pientä aluetta ilmakuvienv keskeltä, koska peittoprosentit olivat niin suuret, että myös brdf:n aiheuttamat ilmiöt olivat melko pieniä.

Kuusten luokittelussa terveisiin, kirjanpainajan sairastuttamiin sekä kuolleisiin kuusiin käytettiin tässä tutkimuksessa reflektanssiin perustuvia piirteitä vihreän, punaisen ja lähi-infran aallonpituusalueilta. Kirjanpainajien aiheuttamia muutoksia saattaa näkyä myös muualla spektrin alueella (taulukko 1). Lisäksi voitaisiin tutkia onko myös muista kuvilta saatavista piirteistä, kuten tekstuuripiirteistä tai erilaisista kasvillisuusindekseistä hyötyä luokittelussa. Myös muiden sensoreiden, kuten laserkeilainten tuottamien piirteiden käyttöä luokittelussa voisi tutkia lisää, sillä erityisesti harsuuntumisen ja näiden piirteiden välillä on havaittu yhteyksiä. Tässä työssä kirjanpainajan aiheuttaman tuhon luokittelussa käytettiin maastosta kerätyistä merkeistä ainoastaan kuusen väriä, sillä sen ajateltiin etukäteen korreloivan spektrin kanssa ja näin olikin, mutta myös muut maastossa kerätyt parametrit korreloivat melko hyvin, joten myös niitä olisi voinut käyttää kuvaamaan kuusen terveyttä. Työn edetessä esitettiin idea näiden parametrien yhdistämisestä nk. terveysindeksiksi esimerkiksi siten, että spektriaineistojen kanssa paremmin korreloivia olisi painotettu enemmän kuin vähemmän korreloivia. Parametrit oli kuitenkin määritelty luokittelusta teikolla, joten tällaisen parametrin laatimista pidettiin vaikeasti perusteltavana. Tällaisen parametrin käyttämistä voisi kuitenkin tutkia paremmin. Parametrissa voisi mahdollisesti huomioida myös muita puun ominaisuuksia, kuten sen pituuden ja rinnanympärysmittan.

Työn tavoitteena oli myös tutkia, miten hyönteistuhoja ja erityisesti kirjanpainajien aiheuttamia tuhoja on aiemmin kaukokartoitettu. Luvussa 2.5 esitettiin näitä keinoja ja kirjanpainajien ja muiden kaarnakuoriaisten aiheuttamia tuhojen kartoituksessa onkin käytetty niin, hyperspektraalista (mm. Fassnacht ym, 2014, Lausch ym. 2013) kuin multispektraalista aineistoa (mm. Meddens ym. 2011). Erona ja myös etuna tässä työssä verrattuna edellä mainittuihin aiempiin tutkimuksiin on se, että tässä tutkimuksessa käsiteltiin yksittäisten puiden spektrejä, kun aiemmissä tutkimuksissa tuhokartat ja analyysit tehtiin pikseleittäin. Tällöin ongelmana on mm. se, että samaan puuhun kuuluvat pikselit saattavat luokittua eri luokkiin. Tätä ongelmaa Meddens ym. (2011) ovat yrittäneet ratkaista pikselikokoa suurentamalla. Tällöin yhteen pikseliin voi kuitenkin sekoittua myös toisiin puuihin tai puuttomiin alueisiin. Kun luokittelua ei rajata koskemaan vain puita, joudutaan luokittelemaan myös tutkimuksen kannalta epäolennaisia alueita, kuten puuttomia ruohikoita, mikä saattaa heikentää luokittelun onnistumista.

Tässä työssä saavutettua luokittelun onnistumista kuvaavaa kappa-arvoa 0,47 voidaan pitää melko hyvänä. Aiemmissä kaarnakuoriaisten tuhojen kartoitusta koskeneissa tutkimuksissa

on saatu myös parempia kappa-arvoja, mutta ne eivät ole aina täysin vertailukelpoisia keskenään, sillä eri tutkimuksissa luokkien määrä ja laatu ovat vaihdelleet. Esimerkiksi Meddens ym. (2011) ovat luokitelleet pikselit kuuteen luokkaan, jotka sisältävät myös varjot ja paljaan maan. He saavuttivat parhaan luokittelutuloksen 2,4 m:n pikselikoolla, jolloin he ilmoittivat kappa-arvoksi 0,875. Lausch ym. saivat parhaimmillaan kappa-arvoksi 0,539, kun he luokittelivat terveet, sairastuneet ja kuolleet puut toisistaan. Fassnacht ym. (2012) taas luokittelivat pikselit kuuteen, luokkaan, joista yksi oli myös maanpinta, saaden kappa-arvoksi 0,888.

Lopuksi voidaan todeta, että FPI-kamera on lupaava vaihtoehto kirjanpainajatuhojen kartoittamiseen. Sen keveyden vuoksi sitä voidaan käyttää useimmilla kuvausalustoilla, myös miehittämättömillä lennokeilla. Muina etuina FPI-kameralla on se, että käytettävät aallonpituusalueet voidaan itse valita sekä se, että kamera valottaa kokonaista kuvaa kerrallaan, jolloin niistä voidaan muodostaa pintamalleja. FPI-kameran, kuten muidenkin spektrikameroiden, eräänä ongelmana puiden kartoituksessa suomalaisissa olosuhteissa on se, että lehtipuiden ollessa lehdettöminä, niiden spektraaliset ominaisuudet muistuttavat kuolleita havupuita, joten kesä ja syksy ovat otollista kuvausaikaa hyönteistuhojen kartoittamiseen FPI-kameralla. Mikäli tuhojen etenemistä on tarkoitus seurata laajemmin ja kuvauksia toistetaan useita kertoja, lehtipuut on toki helppo luokitella lehdellisenä aikana ja rajata nämä puut luokittelun ulkopuolelle lehdettömänä aikana. Myös työssä esiin tullut monivaiheinen prosessi FPI-kameran raakakuvista tuhokartaksi saattaa aiheuttaa haasteita kameran käytölle kirjanpainajatuhojen kartoitukseen mutta nämä prosessit kehittyvät koko ajan ja ne ovat pitkälle automatisoitavissa. Tässä työssä esitetyjä menetelmiä onkin tarkoitus käyttää ja kehittää edelleen kirjanpainajatuhojen kartoituksessa, sillä mm. Lahden kirjanpainajatuhoalueelta on kerätty lisää maastokoealoja vuonna 2014, jolloin luultavasti saadaan lisää aineistoa kirjanpainajien sairastuttamien puiden spektreistä. Lisäksi on tarkoitus tutkia näiden tuhojen kartoitusta myös lennokista kerätyn aineiston avulla.

Lähteet

- BAE Systems., 2007. Next-generation Automatic Terrain Extraction (NGATE). [Viitattu: 17.10.2014]. Saatavilla: http://www.socetgxp.com/docs/education/white_papers/wp_ngate.pdf.
- BENTZ, B.J., RÉGNIÈRE, J., FETTIG, C.J., HANSEN, E.M., HAYES, J.L., HICKE, J.A., KELSEY, R.G., NEGRÓN, J.F. & SEYBOLD, S.J., 2010. Climate change and bark beetles of the western United States and Canada: direct and indirect effects. *Bioscience*, vol. 60:8, s. 602-613.
- CHENG, T., RIVARD, B., SÁNCHEZ-AZOFEIFA, G.A., FENG, J. & CALVO-POLANCO, M., 2010. Continuous wavelet analysis for the detection of green attack damage due to mountain pine beetle infestation. *Remote Sensing of Environment*, 4/15, vol. 114: 4, s. 899-910 DOI: 10.1016/j.rse.2009.12.005. ISSN: 0034-4257.
- CHRISTIANSEN, E. & BAKKE, A., 1988. The spruce bark beetle of Eurasia. Teoksessa: *Dynamics of forest insect populations*, toim. BERRYMAN, A. New York, s. 479-503.
- COHEN, J., 1968. Weighted kappa: Nominal scale agreement provision for scaled disagreement or partial credit. *Psychological bulletin* vol.70:4 s. 213-220.
- DE CARVALHO, O. & P.R. MENESES, 2000. Spectral correlation mapper (SCM): an improvement on the spectral angle mapper (SAM). *Summaries of the 9th JPL Airborne Earth Science Workshop*, JPL Publication 00-18. Saatavilla: ftp://popo.jpl.nasa.gov/pub/docs/workshops/00_docs/Osmar_1_carvalho__web.pdf
- FACCOLI, M., 2009. Effect of weather on *Ips typographus* (Coleoptera Curculionidae) phenology, voltinism, and associated spruce mortality in the southeastern Alps. *Environmental Entomology*, vol. 38:2, s. 307-316. DOI: 10.1603/022.038.0202
- FASSNACHT, F.E., LATIFI, H., GHOSH, A., JOSHI, P.K. & KOCH, B., 2014. Assessing the potential of hyperspectral imagery to map bark beetle-induced tree mortality. *Remote Sensing of Environment*, vol. 140, s. 533-548 ISSN 0034-4257. DOI: 10.1016/j.rse.2013.09.014.
- FASSNACHT, F.E., LATIFI, H. & KOCH, B., 2012. An angular vegetation index for imaging spectroscopy data—Preliminary results on forest damage detection in the Bavarian National Park, Germany. *International Journal of Applied Earth Observation and Geoinformation*, vol. 19, s. 308-321. DOI: 10.1016/j.jag.2012.05.018. ISSN: 0303-2434.
- Finlex., 2013. Laki metsätuhojen torjunnasta. [Viitattu: 9.10.2014]. Saatavilla: <http://www.finlex.fi/fi/laki/alkup/2013/20131087>

- FITZGERALD, G.J., MAAS, S.J. & DETAR, W.R., 2004. Spider mite detection and canopy component mapping in cotton using hyperspectral imagery and spectral mixture analysis. *Precision Agriculture*, vol. 5:3, s. 275-289 AGRICOLA. ISSN: 1385-2256.
- HAKALA, T., HONKAVAARA, E., SAARI, H., MÄKYNEN, J., KAIVOSOJA, J., PESONEN, L. & PÖLÖNEN, I., 2013. Spectral imaging from UAVs under varying illumination conditions. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XL-1/W2*, s. 189–194. Doi: 10.5194/isprsarchives-XL-1-W2-189-2013
- HEURICH, M., OCHS, T., ANDRESEN, T. & SCHNEIDER, T., 2010. Object-orientated image analysis for the semi-automatic detection of dead trees following a spruce bark beetle (*Ips typographus*) outbreak. *European Journal of Forest Research*, vol. 129:3, s. 313-324. Doi: 10.1007/s10342-009-0331-1
- HIRSCHMÜLLER, H., 2005 Accurate and efficient stereo processing by semi-global matching and mutual information. *IEEE Computer Vision and Pattern Recognition*, vol. 2, s. 807-814.
- HONKAVAARA, E., KAIVOSOJA, J., MÄKYNEN, J., PELLIKKA, I., PESONEN, L., SAARI, H., SALO, H., HAKALA, T., MARKELIN, L. & ROSNELL, T., 2012. Hyperspectral reflectance signatures and point clouds for precision agriculture by light weight UAV imaging system. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences I-7*, s. 353-358. Doi: 10.5194/isprsannals-I-7-353-2012
- HONKAVAARA, E., SAARI, H., KAIVOSOJA, J., PÖLÖNEN, I., HAKALA, T., LITKEY, P., MÄKYNEN, J. & PESONEN, L., 2013. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. *Remote Sensing*, vol. 5:10, s. 5006-5039. Doi:10.3390/rs5105006
- HYYPÄ, J. & INKINEN, M., 1999. Detecting and estimating attributes for single trees using laser scanner. *The Photogrammetric Journal of Finland*, vol. 16:2, s. 27-42.
- JÖNSSON, A., APPELBERG, G., HARDING, S. & BÄRRING, L., 2009. Spatio-temporal impact of climate change on the activity and voltinism of the spruce bark beetle, *Ips typographus*. *Global Change Biology*, vol. 15:2, s. 486-499.
- KAARTINEN, H., HYYPÄ, J., YU, X., VASTARANTA, M., HYYPÄ, H., KUKKO, A., HOLOPAINEN, M., HEIPKE, C., HIRSCHMUGL, M. & MORSDORF, F., 2012. An international comparison of individual tree detection and extraction using airborne laser scanning. *Remote Sensing*, vol. 4:4, s. 950-974.
- KANTOLA, T., VASTARANTA, M., LYYTIKÄINEN-SAARENMAA, P., HOLOPAINEN, M., KANKARE, V., TALVITIE, M. & HYYPÄ, J., 2013. Classification of needle loss of individual Scots pine trees by means of airborne laser scanning. *Forests*, vol. 4:2, s. 386-403. Doi: 10.3390/f4020386

- KANTOLA, T., VASTARANTA, M., YU, X., LYYTIKAINEN-SAARENMAA, P., HOLOPAINEN, M., TALVITIE, M., KAASALAINEN, S., SOLBERG, S. & HYYPPA, J., 2010. Classification of defoliated trees using tree-level airborne laser scanning data combined with aerial images. *Remote Sensing*, vol. 2:12, s. 2665-2679.
- KÄRVEMO, S. & SCHROEDER, L.M., 2010. A comparison of outbreak dynamics of the spruce bark beetle in Sweden and the mountain pine beetle in Canada (Curculionidae: Scolytinae). *Entomologisk Tidskrift*, vol. 131:3, s. 215-224.
- LAUSCH, A., HEURICH, M., GORDALLA, D., DOBNER, H., GWILLYM-MARGIANTO, S. & SALBACH, C., 2013. Forecasting potential bark beetle outbreaks based on spruce forest vitality using hyperspectral remote-sensing techniques at different scales. *Forest Ecology and Management*, 11/15, vol. 308, s. 76-89 ISSN 0378-1127. Doi: 10.1016/j.foreco.2013.07.043.
- LAWRENCE, R. & LABUS, M., 2003. Early detection of Douglas-fir beetle infestation with subcanopy resolution hyperspectral imagery. *Western Journal of Applied Forestry*, vol. 18:3, s. 202-206.
- LECKIE, D.G., CLONEY, E. & JOYCE, S.P., 2005. Automated detection and mapping of crown discolouration caused by jack pine budworm with 2.5 m resolution multispectral imagery. *International Journal of Applied Earth Observation and Geoinformation*, 5, vol. 7:1, s. 61-77. Doi: 10.1016/j.jag.2004.12.002. ISSN 0303-2434.
- LILLESAND, M., KIEFER, W. & CHIPMAN, N. J., 2008. Remote sensing and image interpretation. 6. painos. New York: John Wiley & Sons. ISBN: 978-0-05245-7
- LOWE, D.G. 1999. Object recognition from local scale-invariant features. *Computer vision. The proceedings of the seventh IEEE international conference on*, Vol. 2, s. 1150-1157.
- MARKELIN, L., HONKAVAARA, E., NÄSI, R., NURMINEN, K. & HAKALA, T., 2014. GEOMETRIC PROCESSING WORKFLOW FOR VERTICAL AND OBLIQUE HYPERSPECTRAL FRAME IMAGES COLLECTED USING UAV. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 1, s. 205-210.
- MARKELIN, L., 2013. Radiometric Calibration, Validation and Correction of Multispectral Photogrammetric Imagery. Väitöskirja, Aalto-yliopisto. Saatavilla: <http://lib.tkk.fi/Diss/2013/isbn9789517112956/isbn9789517112956.pdf> ISBN (painettu): 978-951-711-294-9. ISSN: 0085-6932.
- MEDDENS, A.J., HICKE, J.A. & VIERLING, L.A., 2011. Evaluating the potential of multispectral imagery to map multiple stages of tree mortality. *Remote Sensing of Environment*, vol. 115:7, s. 1632-1642.

MEIGS, G.W., KENNEDY, R.E. & COHEN, W.B., 2011. A Landsat time series approach to characterize bark beetle and defoliator impacts on tree mortality and surface fuels in conifer forests. *Remote Sensing of Environment*, vol. 115:12, s. 3707-3718 Doi: 10.1016/j.rse.2011.09.009. ISSN 0034-4257.

Metsäkeskus, 2014. Kirjanpainajakuoriainen voi aiheuttaa jopa 10 miljoonan euron vahingot, tiedote, [viitattu 9.10.2014]. Saatavilla: <http://www.metsakeskus.fi/sites/default/files/smk-mediatiedote-kirjanpainajakuoriainen-voi-aiheuttaa-10-milj-tuhot.pdf>.

MIRIK, M., MICHELS, G.J., KASSYMZHANOVA-MIRIK, S., ELLIOTT, N.C. & BOWLING, R., 2006. Hyperspectral spectrometry as a means to differentiate uninfested and infested winter wheat by greenbug (Hemiptera: Aphididae). *Journal of Economic Entomology*, vol. 99:5, s. 1682-1690.

MML 2014a. Maanmittauslaitoksen ortokuva, [viitattu 31.10.2014]. Saatavilla: <http://www.maanmittauslaitos.fi/digituotteet/maanmittauslaitoksen-ortokuva>.

MML, 2014b. Korkeusmalli 2 m, viitattu: [31.10.2014]. Saatavilla: <http://www.maanmittauslaitos.fi/digituotteet/korkeusmalli-2-m>.

MÄKYNEN, J., C. HOLMLUND, H. SAARI, K. OJALA & T. ANTILA., 2011. Unmanned aerial vehicle (UAV) operated megapixel spectral camera. *SPIE Security Defence*. Doi: 10.1117/12.897712

PITKÄNEN, J., 2001. Individual tree detection in digital aerial images by combining locally adaptive binarization and local maxima methods. *Canadian Journal of Forest Research*, vol. 31:5, s. 832-844.

PÖLÖNEN, I., 2013. Discovering knowledge in various applications with a novel hyperspectral imager. Väitöskirja, Jyväskylän yliopisto. Saatavilla: https://jyx.jyu.fi/dspace/bitstream/handle/123456789/42612/978-951-39-5538-0_vaitos14122013.pdf?sequence=1. ISBN: 978-951-39-5537-3 (painettu). ISSN: 1456-5390

PÖLÖNEN, I., H. SAARI, J. KAIVOSOJA, E. HONKAVAARA & L. PESONEN., 2013. Hyperspectral imaging based biomass and nitrogen content estimations from light-weight UAV. *SPIE 8887, Remote Sensing for Agriculture, Ecosystems, and Hydrology XV*, 88870J. Doi:10.1117/12.2028624

PONTIUS, J., MARTIN, M., PLOURDE, L. & HALLETT, R., 2008. Ash decline assessment in emerald ash borer-infested regions: A test of tree-level, hyperspectral technologies. *Remote Sensing of Environment*, 5/15, vol. 112, no. 5, s. 2665-2676 ISSN 0034-4257. Doi: 10.1016/j.rse.2007.12.011.

PRABHAKAR, M., PRASAD, Y., THIRUPATHI, M., SREEDEVI, G., DHARAJOTHI, B. & VENKATESWARLU, B., 2011. Use of ground based hyperspectral remote sensing

for detection of stress in cotton caused by leafhopper (Hemiptera: Cicadellidae). *Computers and Electronics in Agriculture*, vol. 79:2, s. 189-198.

QIN, J., BURKS, T.F., RITENOUR, M.A. & BONN, W.G., 2009. Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *Journal of Food Engineering*, 7, vol. 93, no. 2, s. 183-191. Doi: 10.1016/j.jfoodeng.2009.01.014. ISSN 0260-8774.

ROTHERMEL, M., K. WENZEL, D. FRITSCH & N. HAALA., 2012. SURE: Photogrammetric surface reconstruction from imagery. *Proceedings LC3D Workshop*, Berlin.

ROUSE JR, J., HAAS, R., SCHELL, J. & DEERING, D., 1974. Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication*, vol. 351, s. 309.

SAARI, H., I. PELLIKKA, L. PESONEN, S. TUOMINEN, J. HEIKKILÄ, C. HOLMLUND, J. MÄKYNEN, K. OJALA & T. ANTILA., 2011. Unmanned Aerial Vehicle (UAV) operated spectral camera system for forest and agriculture applications. *SPIE 8174, Remote Sensing for Agriculture, Ecosystems, and Hydrology XIII*, 81740H. Doi:10.1117/12.897585

SMITH, G.M. & MILTON, E.J., 1999. The use of the empirical line method to calibrate remotely sensed data to reflectance. *International Journal of Remote Sensing*, vol. 20:13, s. 2653-2662.

STONE, C., CHISHOLM, L. & COOPS, N., 2001. Spectral reflectance characteristics of eucalypt foliage damaged by insects. *Australian Journal of Botany*, vol. 49:6, s. 687-698.

THENKABAIL, P.S., SMITH, R.B. & DE PAUW, E., 2000. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. *Remote Sensing of Environment*, vol. 71:2, s. 158-182.

TREITZ, P., V. THOMAS, P. ZARCO-TEJADA, P. GONG & P. CURRAN., 2010 *Hyperspectral remote sensing for forestry*. American Society for Photogrammetry and Remote Sensing (ASPRS), 107 s. ISBN: 978-1-570830-93-2

UUTTERA, J., HAARA, A., TOKOLA, T. & MALTAMO, M., 1998. Determination of the spatial distribution of trees from digital aerial photographs. *Forest Ecology and Management*, vol. 110:1, s. 275-282.

VASTARANTA, M., KANTOLA, T., LYYTIKÄINEN-SAARENMAA, P., HOLOPAINEN, M., KANKARE, V., WULDER, M.A., HYYPPÄ, J. & HYYPPÄ, H., 2013. Area-based mapping of defoliation of scots pine stands using airborne scanning LiDAR. *Remote Sensing*, vol. 5:3, s. 1220-1234.

WALTHALL, C., NORMAN, J., WELLES, J., CAMPBELL, G. & BLAD, B., 1985. Simple equation to approximate the bidirectional reflectance from vegetative canopies and bare soil surfaces. *Applied Optics*, vol. 24:3, s. 383-387.

WERMELINGER, B., 2004. Ecology & management of the spruce bark beetle *Ips typographus*—a review of recent research. *Forest Ecology and Management*, vol. 202:1, s. 67-82.

WU, C., 2013 Towards linear-time incremental structure from motion. *3DTV-Conference, International Conference*, s. 127-134.

WU, C., S. AGARWAL, B. CURLESS & S.M. SEITZ., 2011. Multicore bundle adjustment. *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*, s. 3057-3064.