

Taimikoiden tiedonkeruun kehittäminen

Loppuraportti, MMM:n Metsätieto ja sähköiset palvelut -hanke, 11.6.2019

Koordinaattori: Itä-Suomen yliopisto, UEF (Timo Tokola)

Partnerit: Helsingin yliopisto, HY (Markus Holopainen, Mikko Vastaranta), Paikkatietokeskus, FGI (Juha Hyyppä, Eija Honkavaara), Luonnonvarakeskus, LUKE (Timo Saksa, Jouni Siipilehto, Jari Miina), Suomen Metsäkeskus (Juho Heikkilä), VTT (Tuomas Häme, Eija Parmes)

Sisältö

1. Hankkeen yleiskuvaus ja tavoitteet.....	3
2. Tutkimusosapuolet ja yhteistyö	4
3. Tutkimustulokset.....	5
3.1. Osahanke 1 – Biometrinen mallinnus ja testaus.	5
Tutkimusosion eteneminen 2016.....	5
Tutkimusosion eteneminen 2017.....	5
Tutkimusosion eteneminen 2018.....	5
3.2. Osahanke 2 – Taimikon puulajin, pituuden ja tiheyden arviointi laserkeilauksen, fotogrammetrian ja hyperspetriaineiston avulla (HY/FGI).....	9
Tutkimusosion eteneminen 2016.....	9
Tutkimusosion eteneminen 2017.....	9
Tutkimusosion eteneminen 2018.....	12
3.3. Osahanke 3 – Satelliittimateriaalien ennusteet laajoille alueille (VTT).....	13
Tavoitteet	13
Tulokset (VTT).....	13
Taimikoiden seuranta satelliittikuvilta 2018 (UEF).....	21
Taimikoiden seuranta satelliittiaikasarjalta 2018 (UEF)	21
3.3. Osahanke 4 – Kalibrointi-ennusteiden käyttö ja testaus.....	23
Tutkimusosion eteneminen 2016.....	23
Tutkimusosion eteneminen 2017.....	23
Tutkimusosion eteneminen 2018.....	27
4. Tulosten arviointi – tulosten tieteellinen merkitys ja käytännön sovellettavuus	29
4.1. Biometrinen mallinnus ja testaus.....	29
4.2. Taimikon ominaisuuksien arviointi eri kaukokartoitusmateriaalien avulla.....	29
4.3. Yhteenveto osahankkeista	32
5. Julkaisut	32
Kirjallisuus.....	34

1. Hankkeen yleiskuvaus ja tavoitteet

Käytännössä taimikoiden etäinventointimenetelmien puutteellisuus on aiheuttanut tarpeen kehittää kaukokartoitusmenetelmiä paremmin taimikoiden puuston tulkintaan soveltuviksi. Tällä hetkellä taimikoiden ongelmallisuus pelkkään laserkeilaukseen pohjautuvissa inventointimenetelmissä johtuu puuston pienestä latvuskootista ja puuston klusteroituneesta sijainnista. Erityisesti ongelmia tuottaa nuorten taimikoiden puulajisuhteiden ja runkoluvun määrittäminen. Korhosen ym. (2013) tutkimuksessa taimikon runkoluvun keskivirhe verrattuna Suvannon ym. (2005) tekemään uudistuskypsyn metsien runkoluvun keskivirheeseen oli kaksinkertainen. Tulosten heikkous selittyy maanpinnan ja pensaskerroksen heijastuksilla, jotka tekevät laserkeilausinventoinnin tuloksista epäluotettavia. Osin tästä syystä taimikoiden hoitotoimenpiteiden tutkiminen etäinventointimenetelmiä apuna käyttäen on keskittynyt taimikonhoitoon, eikä esimerkiksi täydennysistutukseen tai varhaisperkaukseen. Tämä hanke koostuu neljästä osahankkeesta, jotka esitellään tässä raportissa erillisinä. Hankkeet integroituvat yhteen osahankkeessa 4.

Hankkeen päätavoite on kehittää menetelmiä taimikon hoidon tarpeen ennustamiseen ja ennusteen arvion luotettavuuden estimointiin. Yleisenä tavoitteena on korvata mahdollisimman suuri osa maastovierailuista uudella menetelmällä. Tiedon pohjalta pystytään tuottamaan taimikon kehitys- ja hoitotoimenpide-ennusteet riittävän tarkasti operatiivista käyttöä varten ilman erillistä taimikkokohtaista maastokäyntiä. Jos tietyt inventoitavat kohteet ovat erittäin epäluotettavia, tuotetaan arvio päätöksentekijälle tiedon luotettavuudesta.

Menetelmällä pystytään eliminoimaan riskittömät kohteet metsänhoidon näkökulmasta ja omavalvonnan avulla pyritään kontrolloimaan toimenpiteiden toteutusta. Alkuperäisessä suunnitelmassa tavoitteet olisi listattu seuraavasti:

1. Taimikon vesakontorjunnan tarpeen tai taimikon kehitystä haittavan kilpailun ennustaminen biometrisillä malleilla; tarkkuus, luotettavuus, ongelmakohdat
2. Taimikon tiheyden ja taimikon kehitystä haittaavan kilpailun ennustaminen ALS-aineistoilla; tarkkuus, luotettavuus, ongelmakohdat
3. Optisten kuvamateriaalien käytön arviointi laajoilla alueilla
4. Ennustemenetelmien yhdistäminen tietojen kalibroimiseksi

Hanke oli jaettu osaprojekteihin seuraavasti:

Osahanke 1 – Biometrinen mallinnus ja testaus

Osahanke 2 – Taimikon ominaisuuksien arviointi eri kaukokartoitusmateriaalien avulla (HY/FGI)

Osahanke 3 – Satelliittimateriaalien vesakko-ennusteet laajoille alueille (VTT)

Osahanke 4 – Kalibrointi-ennusteiden käyttö ja testaus (UEF)

Tavoitteita tutkittiin useissa eri osahankkeissa ja tässä esitellään tuloksia kootusti

2. Tutkimusosapuolet ja yhteistyö

Hankkeen toteutukseen osallistuvat seuraavat tahot:

Itä-Suomen yliopisto (UEF), jonka vastuulla oli hankkeen koordinointi, yhteistyön sovittaminen muiden käynnissä olevien hankkeiden kanssa, manuaalisen aineiston keruun toteutus, Työpaketin 4 (TP4) tulosten laskenta ja raportointi, ja osallistuminen muiden pakettien toteutukseen. Hankkeen johtajana toimi Timo Tokola. Hankkeeseen palkattuina osallistuvat lisäksi: Roope Ruotsalainen, Parvez Rana, Zhengyang Hou ja Ulla Mattila. Tässä osassa Suomen metsäkeskuksen osuus rajoittui kuviotietojen aineistojen luovutukseen, joka hoidettiin Juho Heikkilän kautta. Joona Piispanen ja Pekka Manninen tekivät aiheesta opinnäytteen Itä-Suomen yliopistoon.

Luonnonvarakeskus (Luke), vastuulla oli TP1. Luken osuuden projektipäällikkönä toimii Timo Saksa. Muina tutkijoina hankkeeseen osallistuivat Jouni Siipilehto, Jari Miina, Aura Salmivaara ja Tiina Sauvula-Seppälä. Juho Turunen teki aiheesta opinnäytteen Itä-Suomen yliopistoon.

Helsingin yliopiston (HY) ja FGI vastuulla on TP2 (osatehtävä 2). Hankkeen vastuuhenkilö Helsingin yliopistolla oli Markus Holopainen ja FGI:ssa Juha Hyyppä. Hankkeen rahoitettuina tutkijoina olivat Mohammad Imangholiloo (HY) ja Xinliang Liang (FGI).

Valtion teknillinen tutkimuskeskus (VTT) vastasi laajojen alueiden optisen kaukokartoitusmenetelmiin liittyvien vesakon tunnistusmenetelmien kehittämisestä (TP 3 VTT:n osuuden vastuututkijana oli Tuomas Häme. Osahankkeeseen osallistuivat myös Eija Parmes, Laura Sirro, Heikki Astola, Renne Tergujeff, Suomen Metsäkeskuksesta Henna Etula ja Lounais-Suomen alueen kenttätöntekijät, Aki Hostikka ja Harri Hytönen, kolmesta Kaakkois-Suomen metsänhoitoyhdistyksestä niiden työntekijät. Lisäksi kaksi professori Miina Rautiaisen opiskelijaa Aalto-yliopistosta, Ziya Yektay ja Atte Korhonen, tekivät vesakkoindeksiin liittyvän harjoitustyön.

3. Tutkimustulokset

3.1. Osahanke 1 – Biometrinen mallinnus ja testaus.

Tutkimusosion eteneminen 2016

Tutkimusosion ensimmäisenä vuotena mallinnettiin Päijät-Hämeen alueelle VMI perusteiset mallit, joita hyödynnettiin kalibrintiosuudessa. Tarkemmat tiedot löytyvät vuoden 2016 etenemisraportista.

Tutkimusosion eteneminen 2017

Alkuvuodesta 2017 laadittiin käsikirjoitus vuoden 2016 malleista ja tuloksista Päijät-Hämeen alueella. Topografinen kosteusindeksi (TWI) saatiin laskettua koko vmi11 taimikkoaineistolle ja etäisyyttä pohjaveteen kuvaava tunnus (DTW) saatiin laskettua lähes kattavasti. Lisäksi oli tarkoitus tarkastella Geologian tutkimuslaitoksen digitaalisten maaperäkarttojen luotettavuutta suhteessa vmi11 maastoinventoinnin maaperätunnuksiin. Aineiston laajentuessa yritetään mallittaa myös turvemaiden taimikoiden tilaa. Alkuperäisenä tavoitteena oli myös selvittää varsinaista vesottumista vesasyntyisten puiden määränä ja vesojen kasvuna. Tämä osoittautui vmi11 aineistossa epäluotettavaksi ja siitä luovuttiin.

Tutkimusosion eteneminen 2018

Alkuvuodesta pidettiin palaveri, jossa sovittiin Liperin testialueelle biometrinen mallien alustavasta rakenteesta. Liperin testiaineisto saatiin valmiiksi ja siihen sovitettua biometriset mallit havu- ja lehtipuuston kokonaisrunkoluvulle ($\ln(N+1)$) ja pituudelle ($\ln(H)$). Myös Liperin testiaineistossa topografinen kosteusindeksi TWI osoittautui merkitseväksi selittäjäksi perinteisten kasvupaikkaluokkien lisäksi. Mallien selitysasteet ja RMSE sekä takaisinmuunnoksen jälkeen laskettu harha ja virheen keskihajonta olivat alla olevan Taulukko 1 mukaiset.

Taulukko 1. Liperin testiaineistoa varten sovitettujen logaritmistien mallien selitysasteet ja keskivirhe. Takaisinmuunnoksen jälkeen ennusteen absoluuttinen harha ja virheen keskihajonta.

malli	N_lehtipuu	H_lehtipuu	N_havupuu	H_havupuu
R ²	14,2	64,9	35,0	82,1
RMSE%	0,948	0,485	0,612	0,412
harha	-944	-0,04	332	-0,02
virheen keskihajonta	6336	1,14	2579	0,68

Vmi11-aineisto kokonaisuudessaan saatettiin mallituskuntoon. GTK karttatietojen tekstimuotoisesta maaperän kuvauksesta tehtiin mallinnukseen sopivia dummy-muuttujia. Samalla tehtiin eri lähteistä saatujen kasvupaikkatunnusten välistä vertailua. GTK karttapalvelusta saatuja maaperätunnuksia (maalaji, lajittuneisuus) sekä jakoa kivennäis- ja turvemaihin verrattiin vmi11-maastotyön vastaaviin tunnuksiin. Näiden välillä havaittiin huomattavia eroja (Taulukko 2). Jos luokitus olisi yhdenmukainen, niin frekvenssit olisivat Taulukon 2 lävistäjällä. Erojen pääasiallinen syy lienee resoluutiossa, joka GTK karttatiedossa on 4 ha, kun taas tarkemmassa vmi11 aineistossa maalaji perustui 3 – 4 maaperänäytteeseen/koeala.

Taulukko 2. GTK:n karttatietoon ja vmi11 maastotyöhön perustuva pintamaan luokitus: -1 = turvema, 0 = muut kivennäismaat, 1 = hienojakoinen lajittunut (savi, hiesu, hieta), 2 = karkea lajittunut (hiekk, sora), 3 = kivikko ja kalliomaa ja 4 = sekalajitteinen/moreeni.

Vmi11 maalaji	GTK maalaji						Yhteensä
	-1	0	1	2	3	4	
-1	336	32	11	6	33	179	597
0	47	97	27	36	76	309	592
1	66	27	100	25	58	196	472
2	1	8	0	3	5	9	26
3	5	2	0	2	94	48	151
4	306	126	39	118	989	2634	4212
Yhteensä	761	292	177	190	1255	3375	6050

Koko vmi11 taimikkoaineistosta laadittiin vaihtoehtoisia malleja kokonaisrunkoluvulle ($\ln(N_{tot})$) ja lehtipuuston osuudelle (P) sekä keskipituuden ennustamiseksi ($\ln(H)$). Lehtipuuosuuden malli oli logistisen regression muotoinen ($P=1/(1+\exp(-bX))$), jolloin vastemuuttuja pysyi loogisesti välillä 0 ja 1. Vaihtoehtoisilla malleilla oli tarkoitus selvittää eri tietolähteistä poimittujen muuttujien luotettavuutta mallien selittäjinä.


Alimman tason ”avoimen datan” mallissa käytettiin GTK maaperätunnusten lisäksi avoimesti saatavaa 16×16 m hilalle laskettuja kosteusindeksejä (TWI ja DTW). Kosteusindeksi TWI osoittautui DTW-indeksiä paremmaksi selittäjäksi tarkastelluissa malleissa. Toisessa vaihtoehdossa käytettiin kasvupaikan tunnuksina vmi11 maastotyön tuloksia. Kahdessa edellä mainitussa mallissa ennustettiin hoitamattomien taimikoiden tiheyttä eli mallit kuvasivat kasvupaikan potentiaalista tiheyttä. Samalla oletettiin, että tieto taimikon perustamistavasta (luontainen, kylvö, istutus) ja maanmuokkauksesta (ei muokkausta, pintamuokkaus: äestys ja laikutus, syvämuokkaus: mätästysmenetelmät ja auraus) olivat saatavilla. Tarkinta lähtötietoa vaatineissa ”täydellisen tiedon” malleissa käytettiin koko aineisto ja samalla huomioitiin erilaiset tehdyt taimikonhoito toimenpiteet (varhaisperkaus ja taimikon harvennus) ja taimikonhoidosta kulunut aika. Kasvupaikan ja keskimääräisen kosteusindeksin (TWI_MEAN) riippuvuus on kuvattu Taulukossa 3 sekä kivennäismaiden, että turvemaiden osalta. Karuimpien CT ja CIT kasvupaikkojen määrä oli vähäinen, mutta silti niiden suuret TWI arvot olivat huolestuttavia, eikä niille löydetty selvää syytä.

Taulukko 3. Keskimääräinen kosteus (TWI_MEAN) kasvupaikkaluokittain, joita kuvataan Etelä-Suomen metsätyyppien ja näitä vastaavien turvekankaiden lyhennyksillä.

Kasvupaikka	kivennäismaa		turvema		koko aineisto	
	TWI_MEAN	n	TWI_MEAN	n	TWI_MEAN	n
OMaT/Rhtkg	7.814	90	9.520	10	7.985	100
OMT/Rhtkg	7.343	842	9.208	188	7.684	1030
MT/Mtkg	7.220	2612	8.835	301	7.387	2913
VT/Ptkg	7.220	1411	8.984	233	7.470	1644
CT/Vtkg	7.373	253	9.207	88	7.846	341
CIT/Jtkg	9.866	7	10.040	4	9.929	11
Kalliomaa	6.043	10			6.043	10


Kokonaistiheyttä kuvaavan mallin selitysaste (R^2) ja RMSE paranivat lähtötiedon tarkentuessa: 1) avoimen datan malli 15,7 % ja 0,724; 2) vmi11 kasvupaikkatieto 20,1 % ja 0,705; 3) taimikonhoitotoimenpiteet huomioiva täydellisen tiedon malli 23,7 % ja 0,700. Logaritmisien mallien RMSE kuvaa suhteellista virhettä.

Kuvassa 1 on MT kasvupaikan taimikon kokonaistiheyden vaihtelu taimikon iän funktiona niin hoitamattomana, kuin taimikon varhaisperkaus tai taimikon harvennus huomioiden. Taimikonhoitotoimenpiteiden dynamiikka saatiin esiin toimenpiteen ja toimenpiteestä kuluneen ajan funktiona muuttujilla Perkaus/(Aika + 1) ja Harvennus/(Aika + 5). Perkauksen jälkeinen tiheys tuoreella kankaalla oli mallin mukaan noin 5000 ja taimikon harvennuksen jälkeen noin 3000 runkoa/ha. Perkauksen jälkeen tiheys nousi nopeasti vesomisesta johtuen. Taimikon harvennus tehtiin selvästi myöhemmin ja siksi kasvatettava puusto esti huomattavan tiheyden lisääntymisen harvennuksen jälkeen (Kuva 1).




Kuva 1. Kokonaisrunkoluku tuoreen kasvupaikan luontaisessa taimikossa aineiston keskiarvoilla (DDY 1100, meriet 120 km, mpy 130 m) ennustettuna. Vaihtoehtoisia kehityksiä on kuvattu hoitamattomalle, varhaisperatulle ja harvennetulle taimikolle. Varhaisperkaus on tehty 4 vuoden ja harvennus 14 vuoden kohdalla.

Kuvan 2 lehtipuuosuuden ennuste kuvattiin tyypillisillä perustamistavoilla kolmelle eri kasvupaikalle: 1) MT istutus, 2) VT kylvö ja 3) CT luontainen. Kasvupaikan ja puuston syntyvän vaikutus lehtipuuosuuteen oli huomattava. Siten istutetuilla tuoreilla kankailla ja sitä paremmilla kasvupaikoilla lehtipuuosuus oli suurimmillaan 61 %, kylvetyllä kuivahkolla kankaalla vastaavasti 33 % ja luontaisesti syntyneillä kuivilla ja tätä huonommilla kasvupaikoilla se oli suurimmillaan 21 % (Kuva 2). Myös lehtipuuosuuden muutosta voitiin kuvata taimikonhoidon ja hoidosta kuluneen ajan funktiona. Jos esimerkiksi kuivan kankaan taimikossa tehtiin harvennus, lehtipuuosuus tippui mallin mukaan 6 %:iin.



Kuva 2. Kasvupaikan ja taimikon syntyttävän vaikutus lehtipuuston suhteelliseen osuuteen taimikon iän funktiona.

Taimikon havu- ja lehtipuuston keskipituuden kehitys saatiin varsin luotettavasti "täydellisen tiedon" vallitessa. Havupuuston osalta selitysaste R^2 oli 87 % ja RMSE 37 % ja lehtipuustolle vastaavasti 61 % ja 54 %. Etenkin havupuuston pituuskehitys oli riippuvainen syntytavasta, taimikonhoidosta, maanmuokkauksesta ja kasvupaikasta. Sigmoidinen pituuskäyrä saatiin aikaiseksi ikämuunnoksilla. Pituusmalleissa oli mukana yhtäaikaaisesti ikä (T), $\ln(T)$ ja $1/T$. Taimikonhoito lisäsi havupuuston keskipituutta, mutta vähensi lehtisekapuuston keskipituutta, koska lehtisekapuuston havupuustolle aiheuttamaa kilpailua pyrittiin vähentämään poistamalla pisimpiä lehtipuita. Esimerkkinä kuvattiin männyn pituuskehitystä Etelä-Suomessa (ddy 1200) eri kasvupaikoilla (Kuva 3A) ja MT kasvupaikan eri syntyttävillä (Kuva 3B).




Kuva 3. Esimerkki männyn pituuskehityksestä eri kasvupaikoilla ja niille tyypillisillä muokkauksilla (A) ja pituuskehitys MT kasvupaikalla eri syntyttävän mukaan hoidetuissa taimikoissa sekä hoitamattomassa luontaisessa taimikossa (B)

3.2. Osahanke 2 – Taimikon puulajin, pituuden ja tiheyden arviointi laserkeilauksen, fotogrammetrian ja hyperspetriaineiston avulla (HY/FGI)

Tutkimusosion eteneminen 2016

Taimikon pituus, runkoluku ja runkoluvun vaihtelu ovat tärkeimmät taimikoista mitattavat tunnuksia ja niiden perusteella voidaan määrittää taimikon metsänhoidollinen hoitotarve. Tutkimusosion tavoitteena on selvittää kontrolloidulla koejärjestelyllä Evon tutkimusalueella (Kuva 4) laserkeilauksen sekä korkean resoluution ilma- ja hyperspektrikuvien kyky mitata näitä taimikon rakenteellisia tunnuksia.



Kuva 4. Tutkimusalue sijaitsee Evolla Hämeenlinnassa (ETRS-TM35 koordinaatit: N 6787000, E 396800). Koealat on merkitty ympyröillä.

Tutkimusosion ensimmäisenä vuotena perusteettiin maastokoealat, joilta tehtiin tarvittavat mittaukset. Lisäksi kaukokartoitusaineistot kerättiin tutkimusalueelta kahtena eri ajankohtana.

Tutkimusosion eteneminen 2017

Kaukokartoitusaineistojen prosessointi

Erityisesti hyperspektriaineistoille on FGI:ssä kehitetty käsittelyprosessi datankeräyksestä lopputuotteeksi. Kerättyjen kaukokartoitusaineistojen prosessointi on aloitettu esiprosessoimalla sekä ratkaisemalla kuvien orientoinnit, jonka tuloksena saadaan tarkat tiedot kuvienottopaikoista ja asennoista. Tämän jälkeen on luotu mm. ortokuvat ja 3d-pistepilvet (DSM generation). Seuraavissa vaiheissa muodostetaan reflektanssimosaikit ja yhdistetään maastohavainnot aineistoon jatkoanalyysjä varten. Käsittelyn tarkoituksena on tuottaa tiheä pistepilvi ja spatiaalisesti suuriresoluutioinen kuvamosaiikki RGB-kuvaineistoista. FPI-kuvilta saadaan hyperspektridataa ja lämpökuvilta tiedot kohteen suhteellisista


lämpötiloista. Kaikki tutkimusta varten kerätyt aineistot on käsitelty ja niistä on laadittu tieteellinen julkaisu:

Analysit


Visuaalinen tarkastelu osoittaa, että aineistot antavat yksityiskohtaista tietoa taimikoista. Aineistojen automaattinen tulkinta sisältää seuraavia vaiheita:

- Metsikkötunnusten laskeminen koealoille
- Koealojen ja kaukokartoitusaineistojen yhdistäminen
- Piirteiden laskeminen koealoille eri kaukokartoitusaineistoista
- Kasvillisuuden korkeutta ja tiheyttä kuvaavien pintamallien laatiminen eri resoluutioilla
- Taimikoiden tiheyttä parhaiten kuvaavien piirteiden etsiminen
- Taimikoiden tiheyden mallintaminen eri kaukokartoitusaineistoista lasketuilla piirteillä.
- Taimikon latvuspeittävyttä kuvaavien tunnusten laskeminen kaukokartoitusaineistoista
- Yksittäisten taimien tunnistaminen pintamalleista
- Taimikon tiheyden ja kaukokartoitusaineistojen latvuspeittävyksien korrelaation analysointi
- Lehdettömään ja lehdelliseen aikaan kerättyjen aineistojen soveltuvuuden arviointi

Alustavien tulosten perusteella RGB-pistepilviltä lasketut koealan tiheyttä kuvaavat tunnuksat korreloivat vahvasti varttuneiden taimikkokoealojen runkoluvun kanssa (Kuva 5), kun taas nuorissa taimikoissa vastaavaa korrelaatiota ei havaittu (Kuva 6).



Kuva 5. Kasvillisuustiheyden korrelaatio runkoluvun suhteen varttuneissa taimikoissa (T2).



Kuva 6. Kasvillisuustiheyden korrelaatio runkoluvun suhteen nuorissa taimikoissa (T2).


Kevät ja kesäkuvilta tuotettujen RGB-pistepilvien avulla tunnistettiin myös yksittäisiä taimia (Taulukko 4). Kahta vaihtoehtoista yksinpuintulkintamenetelmää (Watershed, ForestCAS) vertailtaessa koealojen runkoluvun määrittämisessä todettiin, että kevätaineistot toimivat puiden tunnistamisessa hieman paremmin.

Taulukko 4. Koealalle tulkittu runkoluku (ha-1) kahdella eri yksinpuintulkintamenetelmällä (Watershed, ForestCAS) RGB-pistepilvien kevät- ja kesäaineistoilla. Vertailukohtana maastossa määritetty runkoluku (Field data).

Plot	Site	Watershed method		ForestCAS method		Field data		
		Spring	Summer	Spring	Summer	total number of tree	spruce	birch
1	T1GT1	1940	1492	1293	2288	1989	1989	0
2	T1GT2	2686	1840	696	995	1790	1790	0
3	T1GT3	1641	2387	647	1293	1194	1194	0
4	T1GT4	2139	1890	348	597	1393	1393	0
5	T1GT5	2437	2387	1094	1442	1592	1592	0
6	T2G1	859	1050	668	987	987	891	95
7	T2G2	477	605	350	605	605	446	159
8	T2G3	1019	1114	1560	1369	1592	1369	223
9	T2G4	1050	1114	2196	1846	1814	1273	541
10	T2G5	1050	1178	1496	1528	1401	1401	0
11	T2G6	1273	1305	2865	2101	2069	2037	32
12	T2G7	1687	1178	4234	2674	2228	1464	764
13	T2G8	1082	1241	2706	2387	2387	1178	1210
14	T2G9	1178	1210	923	1241	1210	1210	0
15	T2G10	732	1146	796	1114	796	796	0
Total sum		21251	21138	21872	22467	23046	20022	3024

Tutkimusosion eteneminen 2018

Alkuvuodesta 2018 viimeisteltiin Evon aineiston sensorikohtaiset testit. Kuvissa 7 ja 8 esitetään esimerkkikoealan havainnot, tulkinta ja visualisointi.




Kuva 7. Esimerkki koealasta ja eri ajankohtien ja sensoreiden kuvamateriaalista ja niiden tulkintatuloksesta.

UAV:sta kuvattu RGB-pistepilvien ja hyperspektridatan yhdistelmä sekä helikopterista kuvattu ALS Titan – aineisto tuottivat melko tarkkoja estimaatteja taimikoiden tiheydelle ja pituudelle (RMSE tiheydelle n. 20% ja pituudelle n. 10%). RGB-pistepilvien ja hyperspektridatan yhdistelmä ja pelkkä ALS-Titan –data tuottivat suurinpiirtein yhtä hyviä tuloksia tiheyden ja pituuden osalta – toisin sanoen näiden tunnusten osalta riittää, että meillä on vain toinen aineisto.

Hyperspektridata paransi puulajiluokittelun tarkkuutta. Taimikon tiheys (600-2400 tainta/ha) ei vaikuttanut merkittävästi tiheys- ja pituusestimaattien tarkkuuteen. Sekä RGB-pistepilvien että ALS –aineiston avulla on mahdollista mitata melko hyvällä tarkkuudella lehtipuiden ja havupuiden (istutettavien / kasvatettavien) puiden pituuseroa.


Only plot	Number of	
T2G9	total trees	Spruce
	(spruce)*	Height (m)
Field data	38	2.45
ALS spring	31	1.91
ALS summer	35	2.25
UAV spring	33	1.95
UAV summer	28	2.33

* This plot has only spruce trees.



Kuva 8. Esimerkki koealasta ja aineiston 3D prosessoinnista: T2- taimikko, ALS Titan vs UAV RGB-pistepilvet ja hyperspektridata

RGB-pistepilvet, hyperspektridata ja ALS TITAN toimivat paremmin T2-taimikoissa kuin T1-taimikoissa – syy: T1-taimikoissa puut sekoittuvat pensaiden, heinien ja kivien kanssa. UAV- pistepilvien ja hyperspektridatan osalta lehdelliseen aikaan tehty kuvaus toimi paremmin sekä tiheys (RMSE% 20%) että pituusmittauksissa (RMSE%= 11.5%) (Kuva6). Sekä ALS TITAN että UAV –estimaatit olivat sekä tiheyden että pituuden osalta jonkin verran harhaisia (aliarvioita). UAV:n käytön etu verrattuna ALS TITAN –dataan: huomattavasti tiheimmät pistepilvet (~30 kertaa tiheimmät)



Kuva 9. Vasemmalla oleva kuvapari: Puuston tiheys lehdettömänä (a) and lehdellisenä (b) ajankohtana, T2 (AdS) ja T1 (YoS) taimikoissa. Vastaavasti oikealla oleva kuvapari puuston keskipituus lehdettömänä (a) and lehdellisenä (b) ajankohtana.

Avoimeksi jäi taimikon tiheyden estimoinnin menetelmien testaaminen tiheissä, yli 2400 tainta / ha taimikoissa. Puulajitulkinnan jatkokehittäminen ja testaaminen vaativat myös tarkennusta.

3.3. Osahanke 3 – Satelliittimateriaalien ennusteet laajoille alueille (VTT)

Tavoitteet

Osahankkeen tavoitteena oli tutkia optisten satelliittikuvien ja varsinkin Sentinel-2 -satelliitin kuvien soveltuvuutta taimikon vesoituneisuuden arviointiin ja kehittää vesoituneisuutta kuvaava indeksi käytännön tarpeisiin tukemaan taimikonhoidon toteuttamista. Lisäksi tavoitteena oli selvittää, miten Forestry Thematic Exploitation Platform ([F-TEP](#)) -pilvipalvelu toimii vesakkoarvioinnin laskenta- ja jakelualustana.

Tavoitteena ei ollut ottaa kantaa kasvatettavaan puulajiin, eikä havupuuston tilaa yritetty arvioida. Myös kasvatettavat lehtipuustot lukeutuivat siten ”vesakoiksi”.

Hanke liittyi läheisesti Suomen Metsäkeskukselle tehtyyn erillistutkimukseen, jossa tutkittiin drone- ja satelliittikuvien yhteiskäyttöä taimikonhoitotarpeen arviointiin ja muun tiedon keräämiseen taimikoista. Drone-hankkeesta VTT teki erillisen raportin Suomen Metsäkeskukselle. Tässä raportissa käsitellään drone-hankkeen tuloksia siltä osin, miten ne täsmensivät ”Satelliittimateriaalien vesakkoennusteet laajoille alueille” -osahankkeessa saatuja tuloksia.

Tulokset (VTT)

Hankkeessa tehtiin tulkintoja kaikkiaan kuudesta Sentinel-2 -satelliittikuvasta (Taulukko 5). Ilmaisissa Sentinel-kuvissa on neljällä aallonpituuskanavalla 10 metrin, kuudella kanavalla 20 metrin ja kolmella 60 metrin maastonerotuskyky. Satelliittikuvan analysoinnilla tavoiteltiin lehtipuustoisuuden havaitsemista uudistusaloilla. Tavoitteena ei ollut arvioida havupuuntaimien määrää tai runkolukuja, vaan suoraan vesakkohaitan astetta. Analyysi ei myöskään ottanut kantaa kasvatettavaan puulajiin, eli pelkän

satelliittikuvan tulkintatuloksen perusteella ei voitu erottaa taimikoita, joissa on tarkoitus kasvattaa lehtipuita. Hypoteesina on, että lehtipuiden havupuita korkeampi lähi-infrapunasäteilyn heijastusarvo korreloi vesoittuneisuusasteen kanssa.

Taulukko 5. Osahankkeessa käytetyt satelliittikuvat ja verrokkiaineisto.

Kuvan ajankohta	Alue	Verrokkiaineisto	Käyttötarkoitus
20.5.2017	Päijät-Häme	Itä-Suomenyliopiston kautta	Esiselvitys
13.9.2016	Lounais-Suomi	Ei	Alustava vesakkoindeksi maastotarkastusta varten
14.8.2017	Lounais-Suomi	Suomen metsäkeskuksen hanketta varten keräämä.	Indeksin rajojen määrittäminen
31.7.2018 ja 11.8.2017	Mänty-Saimaan, Kymenlaakson ja Etelä-Karjalan metsänhoitoyhdistyksen alueet	Suomen metsäkeskuksen metsävara, dronekuvien visuaalinen tulkinta, maastokäynnit	Indeksin rajojen täsmäntäminen, luotettavuusarviot
31.7.2018	Liperi, Joensuun ympäristö	Itä-Suomen yliopiston maastokoealat	Hankkeen tulosten liittäminen muiden osahankkeiden tuloksiin


Aiemman tietämyksen ja alustavien kokeilujen jälkeen päädyttiin vesakoitumisen arviointimenetelmä perustaa paljon käytettyyn kasvillisuusindeksiin Normalized Difference Vegetation Index eli NDVI (Kaava 1).

$$NDVI = \frac{NIR-red}{NIR+red}, missä \quad (1)$$

NIR on lähi-infrapunasäteilyn (aallonpituus noin 0,8 - 0,9 µm) heijastuksen voimakkuus

red punaisen valon (noin 0,6 - 0,7 µm) heijastuksen voimakkuus

Lähi-infrapunasäteilyn ja punaisen valon aallonpituuskanavien erotuskyky Sentinel-2 -aineistossa on 10 metriä, jolloin tulokset voitiin laskea tällä tarkkuudella. Indeksia käytetään paljon maatalousmaiden kasvibiomassan ja metsissä lehtialaindeksiin arviointiin. Indeksillä on myös se ominaisuus, että lehtipuut saavat suomalaisia havupuulajeja korkeammat arvot, vaikka puiden biomassassa olisi samankaltainen. Vesakon tunnistaminen perustuu tähän ilmiöön (Häme 1984).



Kuva 10. Vesakkoluokituksen kehitysvaiheet. Metsäkeskuksen osuus vihreissä laatikoissa.

Verrokkiaineiston keräämistä varten tehtiin alustava vesakkoluokitus 13.9.2016 -kuvan NDVI:n luokituksella (Kuva 10). Indeksi jaettiin viiteen luokkaan, joiden rajat valittiin interaktiivisesti. Luokille tehtiin kvalitatiivinen sisältömäärittely yhteistyössä Metsäkeskuksen kanssa. Luokituksen tavoitteena oli tuottaa ositteet maasto-otosta varten. Metsäkeskus teki vastaavan viisiportaisen vesoittuneisuusluokituksen (Taulukko 6). Luokitusjärjestelmä poikkesi olennaisesti Metsäkeskuksen käyttämästä kvantitatiivisesta taimikoiden koeala-arvioinnista.

- NDVI < 0.5 - ei vesakkoa 0
- $0.50 < \text{NDVI} < 0.53$ - lievä vesakko 1
- $0.53 \leq \text{NDVI} < 0.55$ - kohtalainen vesakko 2
- $0.55 \leq \text{NDVI} < 0.57$ - runsas vesakko 3
- $0.57 \leq \text{NDVI}$ - erittäin runsas vesakko 4.

Taulukko 6. Metsäkeskuksen vesoittuneisuusluokitus maastotyötä varten.


SELITTEET

Vesakoitumisaste	Metsänhoidollinen toimenpide / ajankohta	Metsikön tila
Ei vesakkoa	Ei hoitotarvetta	Kuviolla ei käytännössä ole lehtipuustoa
Lievä vesakko	Ei välitöntä hoitotarvetta	Lehtipuusto ei vielä haittaa havupuuston kehitystä
Kohtalainen vesakko	Taimikonhoito / varhaishoito, 1-5 vuoden kuluessa	Havupuusto ei ole vielä merkittävästi kärsinyt lehtipuuston kilpailusta
Runsas vesakko	Taimikonhoito / varhaishoito, heti	Havupuusto on jo kärsinyt lehtipuuston kilpailusta
Erittäin runsas vesakko	Taimikonhoito / varhaishoito, myöhässä oleva hoitotoimenpide	Havupuusto on jo kärsinyt selvästi lehtipuuston kilpailusta

Korkeat NDVI-arvot edustivat siis runsasta ja matalat alhaista lehtipuustoisuutta. Luokitusta käytettiin ositetun otannan pohjana. Jokaisesta vesakko-ositteesta valittiin 40 eli yhteensä 200 taimikkoa. Otantamenetelmä oli yksinkertainen satunnaisotanta maantieteellisellä osituksella, jotta maastotyötä

voitiin järkiperaistää. Tiedot valituista taimikoista toimitettiin Metsäkeskukseen. Toimitukseen ei sisältynyt tietoa alustavasta satelliittikuvatulkinnan tuloksesta.

Kevään ja kesän 2017 aikana Metsäkeskus tarkasti otoksesta maastossa 102 taimikkoa (Kuva 11). Tarkastajat kirjasiivat maastossa taimikon pinta-alan jakauman vesakkoluokkiin. Taulukkomuotoisen tiedonkeräyksen lisäksi tarkastajat ottivat taimikoista matkapuhelimella valokuvat, jotka siirtyivät VTT:n palvelimeen hankkeessa kehitetyn menettelyn avulla (Kuva 12).




Kuva 11. Lounais-Suomessa tarkastetut taimikot.



Kuva 12. Esimerkkejä Lounais-Suomessa tarkastetuista taimikoista. Kuvat Suomen metsäkeskus.

Maastossa tarkastettujen taimikoiden sävyarvot poimittiin 13.9.2016 ja 14.8.2017 otetuista satelliittikuvista ja niiden jakaumia verrattiin maastossa tehtyihin vesakkoluokituksiin. Analyysin perusteella tehtiin varsinainen NDVI-indeksiin perustuva vesakkoluokitus. Luokitusta testattiin uusiin kuviin Kaakkois-Suomen alueella, minkä jälkeen indeksistä ohjelmoitiin sovellus Forestry Thematic Exploitation Platformiin (<https://F-TEP.com>). Indeksiin perustuva luokitus toimitettiin myös Itä-Suomen yliopiston Liperin tutkimusalueesta.




Kuva 13. Kolmen vähiten vesoittuneeseen luokkaan ja kolmen eniten vesoittuneeseen luokkaan kuuluneen taimikon sävyarvojakaumat alkuperäisissä aallonpituuskanavissa ja kahden indeksin arvot. Vaaka-akseli: heijastuksen voimakkuus prosentin sadasosina (1=100%), pystyakseli: havaintojen määrä. Sentinel-2 -satelliittikuva 14.8.2017.

Maastossa tarkastetuista 102 taimikosta löytyi 11 taimikkoa, joiden pinta-alasta yli 90% oli maastossa arvioitu kuuluneen vähiten vesoittuneeseen luokkaan. Yhdeksän taimikkoa edusti samalla kriteerillä eniten vesoittunutta luokkaa. Nämä kaksi ryhmää otettiin alustavien analyysien jälkeen lähempään tarkasteluun vesakkoindeksin kehittämiseksi.

Kuva 13:stä nähdään, että maastossa eniten vesoittunutta luokkaa edustaneiden taimikoiden lähi-infrapunasäteilyn (NIR) heijastus oli selkeästi suurempi kuin vähiten vesoittuneen luokan taimikkojen. Sama koskee kasvillisuusindeksi NDVI:tä sekä NIR-kanavan että punaisen valon suhdetta (nirDivRed). Sen sijaan näkyvän valon aallonpituuskanavissa ei ole nähtävissä vastaavaa ilmiötä (Blue, Green, Red). Jakaumat kuitenkin peittävät osittain toisensa, varsinkin taimikossa nro 6. NDVI valittiin vesakon indikaattoriksi, koska sen laskeminen korjaa verrattain hyvin ilmakehän vaikutusta kuvan sävyarvoihin. Kuvien autereisuus vaihtelee, ja korjaamatta jääneet suuret vaihtelut aiheuttavat virheitä tuloksiin.

Samojen taimikkojen NDVI-arvot olivat elokuun kuvassa selvästi korkeammat kuin maasto-otokseen käytetyt syyskuun kuvan arvot. Myös vesakkoluokkien erot olivat syyskuun kuvassa pienemmät. Lehtien ja olettavasti myös kenttäkerroksen kasvillisuuden kellastuminen nosti myös näkyvän valon aallonpituuskanavien arvoja, mikä alensi NDVI:n arvoja. Syyskuun kuvan avulla pystyttiin tekemään ositus maastokoealojen valitsemiseksi, mutta sen todettiin soveltuvan vesakoitumisen määrän arviointiin silti heikokosti.

Maastossa otetut kuvat paljastivat, että taimikoiden vesoittumisen määrä ja taimitiheys vaihtelivat niiden sisällä, mikä vaikeutti sekä maasto- että satelliittiarviointia (Kuva 12). Tästä arveltiin johtuneen, että eri asteista vesoittuneisuutta edustaneiden väliluokkien erot satelliittikuvissa olivat pieniä. Vesakkoindeksi perustettiin kahteen äärimmäiseen maastoluokkaan, jotka määrittivät NDVI:hin perustuvan vesakkoindeksin minimi- ja maksimiarvot. Valittujen minimi- ja maksimiarvojen väliset NDVI-arvot jaettiin tasavälein siten, että päädyttiin alkuperäisiin viiteen vesakkoluokkaan.



Kuva 14. Kahdesta vuosien 2017 ja 2018 Sentinel-2 -kuvasta laskettu ilmakehäkorjattu mosaiikki Kaakkois-Suomesta.

Indeksin testaus ja jatkokehitys Kaakkois-Suomessa

Lounais-Suomessa kehitetty vesakkoluokitus osoittautui toimivan sellaisenaan Metsäkeskuksen tekemissä maastotarkastuksissa lukuun ottamatta varhaisperkausikäisiä taimikoita, joissa perkauksen tarpeessa olleet taimikotkin luokittuivat usein ei-vesoittuneisiin luokkiin (Kuva 14). Tarkastusten perusteella indeksiä laajennettiin kahdella luokalla alempiin NDVI-arvoihin, jotta arvioita pystyttiin tekemään myös nuorista taimikoista. Lopullinen NDVI-indeksiin perustuva taimikkoluokitus esitetään Taulukko 7:ssä ja


Taulukko 8:ssä. F-TEP -pilvipalveluun tehty sovellus tuottaa tuloksen värillisenä tiff-kuvana (Kuva 15, Kuva 16). Sovelluksessa oletusarvoina ovat tässä raportissa esitetyt NDVI-luokkarajat, mutta käyttäjä voi muuttaa niitä haluamallaan tavalla. Sovellus ei tavoittele taimikoiden erottamista ympäristöstään eikä se ota kantaa kuvien mahdolliseen pilvisyyteen. Varsinaiset pilvet ja niiden varjot erottuvat alhaisen NDVI-arvon perusteella ja menevät Taulukko 7:n luokkaan 1. Ohuet pilvet saattavat aiheuttaa vesoittuneen taimikon lukeutumisen lievän vesakon luokkiin.

Taulukko 7. Vesakkoluokitus värikoodeineen. Värikoodit viittaavat F-TEP -sovelluksen.


luokka	kuvaus	NDVI-raja-arvot		väri	
1	Asutus, vesi, pilvet, pilven varjot	NDVI <=	0.2	valkoinen	255 255 255
2	Ei vesakkoa	0.2 < NDVI <=	0.4	siniharmaa	150 140 170
3	Hyvin lievää vesakkoa	0.4 < NDVI <=	0.5	tumm.viol.	170 10 200
4	Lievää vesakkoa	0.5 < NDVI <=	0.6	magenta	255 35 220
5	Kohtalaisen lievää vesakkoa	0.6 < NDVI <=	0.68	vihreä	56 168 0
6	Kohtalaista vesakkoa	0.68 < NDVI <=	0.713	kellavihreä	163 255 115
7	Selkeästi vesoittunut	0.713 < NDVI <=	0.747	keltainen	255 255 0
8	Runsasta vesakkoa	0.747 < NDVI <=	0.78	oranssi	230 152 0
9	Erittäin runsasta vesakkoa	0.78 < NDVI <=	1.00	punainen	255 0 0

Taulukko 8. Yksinkertaistettu vesakkoluokitus värikoodeineen. Värikoodit viittaavat F-TEP -sovelluksen.

luokka	kuvaus	NDVI-raja-arvot			väri
1	asutus, vesi, pilvet, pilven varjot	NDVI <=	0.2	valkoinen	255 255 255
2+3+4	Ei vesakkohaittaa	0.2 < NDVI <=	0.6	magenta	255 35 220
5+6	Lievä vesakkohaitta	0.6 < NDVI <=	0.713	kellanvihreä	163 255 115
7+8+9	Merkittävä vesakkohaitta	0.713 < NDVI <=	1.00	punainen	255 0 0



Kuva 15. F-TEP -pilvipalvelun käyttöliittymä. Vesakkopalvelu saadaan käyttämällä sovelluksia VegetationIndices ja QuantizeNDVI3.



Kuva 16. Kahdesta vuosien 2017 ja 2018 kalibroimattomasta Sentinel-2 -kuvasta laskettu kuvasta laskettu vesakkoindeksi Kaakkois-Suomesta. Laskennan jälkeen värikoodaus muutettiin Taulukko 7:n mukaiseksi.


Toteutusvaiheen arviointi

Osahankkeessa pystyttiin kehittämään luokitus, joka osoittautui hyödylliseksi käytännön taimikonhoitotarpeen määrittelyyn. Luotettavan maastoaineiston saaminen oli työlästä, jolloin mahdollisuus kvantitatiiviseen tulosten arviointiin oli rajallinen. Sekä Metsäkeskuksen että Itä-Suomen yliopiston keräämän koala-aineiston hyödyntäminen oli hankalaa, maastossa kerättyjen muuttujen

luonteen ja koordinaattien osittaisen epäluotettavuuden takia, mikä korostui taimikoiden sisäisen heterogeenisuuden vuoksi. Erillisessä drone-osahankkeessa paneuduttiin luotettavan maastoaineiston keräämiseen, mutta ensimmäistä kertaa tehdyt kuvaukset eivät palvelleet vesakkoanalyysiä optimaalisesti, sillä aineiston visuaalinen tulkinta oli verraten epäluotettavaa.

Taimikoiden seuranta satelliittikuvilta 2018 (UEF)

VTT:n vesakko tulkin (NDVI luokkien) ja koealojen runkolukutietoja vertailtiin Liperin taimikkokoelaoilla. Kokonaisrunkoluvun kanssa oli havaittavissa trendiä, mutta luokkiin sisältyi suurta epävarmuutta (Kuva 17). Kun alle 2500 runkolukujen (<2500) taimikoissa painotettiin taimikon pituudella, niin taimikonhoidon tarve oli pahimpien kohteiden osalta jotenkin ennustettavissa. Ennusteisiin liittyi kuitenkin paljon epävarmuutta, mikä on luonnollista johtuen satelliittikuvien mittaustekniikasta eli kohteiden heijastussäteilyn variaatiosta.




Kuva 17. VTT:n vesakko-indeksin ja kokonaisrunkoluvun relaatio Liperin koealoilla (vasen). Vastaavasti alle 2500 runkoluvun metsiköiden relaatio pituudella painotettuun tiheyteen.

Taimikoiden seuranta satelliittiaikasarjalta 2018 (UEF)

Satelliittikuvien aikasarjojen analysointi on kehittynyt nopeasti kuvien saatavuuden parannuttua. Landsat kuvista muodostettiin 14 vuoden aikasarja Liperin aineistolle. Testissä käytettiin 371 koealaa ja käytettiin NBR indeksiä. NBR on spektri-indeksi, jonka esitteli Key&Benson (2006) palojen vaikutusten vakavuuden kartoitukseen to ja laskettiin Landsat ETM+ kanavien 4 (B4; near-infrared) ja 7 (B7; shortwave-infrared) suhteena seuraavasti:

$$NBR = \frac{B4 - B7}{B4 + B7} \quad (2)$$


NBR arvot vaihtelevat -1 ja 1 välissä, jolloin positiiviset arvot indikoivat kasvillisuutta ja negatiiviset arvot ovat paljaan maan dominoivia alueita (Escuin et al. 2008).



Kuva 18. Esimerkki uudistamisajankohdan aiheuttamasta NBR indeksin muutoksesta Liperin aineistossa.

Taimikoiden uudistusajankohta on helppo identifioida automaattisesti (Kuva 18). Arvojen keskiarvojen ja hajontojen perusteella on helppo arvioida, että taimikoiden kasvillisuuden lisäys näkyy aikasarjoissa selvästi ja uudistamisajankohta on mahdollista määrittää automaattisesti yhden vuoden tarkkuudella 100 % :sti.

Kokonaisrunkoluvun ja indeksin välinen yhteys uudistamisen jälkeen on trendinomainen.. Seuraavassa viiteen tiheysluokkaan jaettu esitys (0: 0..<3000; 1: >=3000 <6000; 2 >=6000..<9000 ; 3 >=9000 ..<12000; 4 >=12000). Indeksien yhteys runkolukuun ei silti ole aivan yksi selitteinen. Taimikon alkuvaiheen ruohittumisen vaikutus varmasti vaikuttaa mahdollisuuksiin havainnoida runkolukua yksiselitteisesti. Toisaalta todella tiheet taimikot (runkoluku >6000) erottuvat hyvin myös satelliittien NBR aineistosta.



Kuva 19. NBR:n arvot viiteen kasvillisuuden tiheysluokkaan (runkoluku) jaettuna (0: 0..<3000; 1: >=3000 <6000; 2 >=6000..<9000 ; 3 >=9000 ..<12000; 4 >=12000).

3.3. Osahanke 4 – Kalibrointi-ennusteiden käyttö ja testaus

Tutkimusosion eteneminen 2016

Tutkimusosion ensimmäisenä vuotena mallinnettiin Päijät-Hämeen alueelle VMI perusteeset mallit, joita hyödynnettiin kalibrointiosuudessa. Kalibrointiestimoinnin tarkoituksena on tuottaa tehokkaat Lidar-ennusteet laajoille alueille. Vuoden 2016 aikana prosessoitiin 1 laaja alue ja hankkeen tutkimusta laajennetaan seuraavana vuosina uusille alueille. Kaukokartoituksen ja biometrinen mallien kalibrointitutkimusta varten hankittiin Suomen metsäkeskuksen taimikoiden tarkistuksia ja kuviotiedot Itä-Päijänteen Kuhmoinen-Padasjoki-Asikkala kattamalta alueelta. Kesällä 2016 alueelta mitattiin hankkeen toimesta n. 50 kuviota. Alueelta prosessoitiin operatiivisia monipuolisesti laserkeilausaineistoja, ilmakuvia ja vanhoja metsäsuunnitelmia. Liperin alueelta mitattiin vuoden 2016 aika n. 100 metsikön taimikot. Tarkemmat tiedot löytyvät vuoden 2016 etenemisraportista.

Tutkimusosion eteneminen 2017

Yleistä

Vuoden 2017 aikana tehtiin useita mallinnustöitä ja kirjoitettiin ensimmäisiä käsikirjoituksia. Seuraavassa esitellään alustavia tuloksia eri keilain aineistoilla ja kalibrointitekniikalla. Lisäksi Liperistä mitattiin vuonna 2017 koealaoja lisää 358 kappaletta.

Standardikeilain

Tämän osatutkimuksen tarkoituksena oli tutkia, voidaanko uusimpien laserkeilausaineistojen ja numeeristen ilmakuvien avulla saada riittävän luotettavaa tietoa taimikon tiheydestä ja pituudesta, jotta sitä voitaisiin hyödyntää taimikonhoidon ajan määrittämisessä. Tutkimusaineisto koostui 42 taimikkokuvista, jotka sijaitsivat Päijät-Hämeessä. Alueen ilmakuvaukset ja laserkeilaus oli suoritettu 2014 ja maastotiedot oli mitattu 2016. Tutkimuksessa tarkasteltiin kuvioiden runkoluvun, lehtipuiden suhdeluvun ja pituuden välistä korrelaatiota tiettyyn tunnukseseen. Tunnuksina käytettiin sekä laserkeilaus- että heijastusarvo-tunnuksia. Tutkimuksessa luotiin myös lineaarisia regressiomalleja selittämään runkolukua, lehtipuiden suhdelukua ja pituutta.

Taulukko 9. Yksittäisten laserkeilaustunnuksien ja sävyarvojen avulla lasketut korrelaatiot.

Kaikuluokan pisteiden määrä	0,5-1 m	1-2 m	2-3 m	3-4 m	4-9 m	Yhteenlaskettu
Kokonaisrunkoluku	-0,153	-0,058	-0,124	-0,042	-0,127	-0,120
Lehtipuiden suhdeluku	0,112	0,246	0,060	0,122	0,177	0,182
Keskipituus	0,643	0,828	0,701	0,579	0,642	0,846
Lähi-infrakanava						
	Keskiarvo	Keskihajonta	Vinous		Huipukkuus	
Kokonaisrunkoluku	0,019	0,255	0,293		-0,154	
Lehtipuiden suhdeluku	-0,099	0,238	0,375		-0,339	
Keskipituus	-0,076	0,101	0,172		-0,563	
Sininen kanava						
	Keskiarvo	Keskihajonta	Vinous		Huipukkuus	
Kokonaisrunkoluku	0,019	0,255	0,293		-0,154	
Lehtipuiden suhdeluku	-0,099	0,238	0,375		-0,339	
Keskipituus	-0,076	0,101	0,172		-0,563	

Heijastusarvotunnusten ja tiheyden välille saatiin vain kohtalaisia korrelaatioita parhaiden ollessa 0,50-0,56. Lehtipuiden suhdeluvun ja kokonaisrunkoluvun välillä erot olivat vähäiset. Laserkeilaustunnuksille saatiin todella huonoja korrelaatioita, kun niitä verrattiin lehtipuiden suhde- tai kokonaisrunkolukuun. Pituuden ja laserkeilaustunnusten välille saatiin hyviä korrelaatioita parhaan korrelaation ollessa 0,846. Sävyarvotunnusten ja pituuden välille saatiin kuitenkin vain kohtalaisia korrelaatioita.

Tiheydelle saatiin luotua mallit ainoastaan käyttämällä selittäjinä sävyarvotunnuksia. Niiden selityssasteet olivat kuitenkin hyvin heikkoja, eikä niitä voida siksi hyödyntää käytännössä. Sävyarvoilla pituudelle luotu malli sai myös heikon selityssasteen. Pituudelle kuitenkin onnistuttiin luomaan laserkeilaustunnuksien avulla lineaarinen regressiomalli, jonka selityssasteeksi saatiin 70,07 %.

Syynä tiheyden arvioinnista saatujen tulosten heikkouteen on voinut olla myös aineiston pieni määrä, koska tarkastelussa oli vain 42 kuviota ja niistäkin osa jouduttiin poistamaan niiden virheellisyyden vuoksi. Tutkielman tulosten heikkouteen on voinut vaikuttaa myös se, että maastomittauksien ja laser-keilausten välillä oli aikaa yli vuosi. Tästä syystä joillakin kuviolla on saatettu tehdä metsänhoitotoimenpiteitä laserkeilausten ja maastomittauksien välillä, esimerkiksi harvennusta. Tällainen toimenpide vaikuttaa tulosten tarkkuuteen huomattavasti, koska laserkeilausaineistossa kuvio näyttää hyvin tiheältä, kun taas maastomittauksissa sen runkoluku eli tiheys on pieni.


Monikanavakeilain

Tässä tutkimuksen osatutkimuksessa aineiston keräämisessä käytettiin uudenlaista monikanavakeilainta, joka mahdollistaa eri aallonpituusalueiden käytön laserkeilauksessa. Tutkimuksessa käytettiin Optechin Titan sensoria (Taulukko 10), joka lähettää pulsseja kolmella eri aallonpituusalueella. Aallonpituudet ovat näkyvän valon vihreää aallonpituusaluetta vastaava 532 nm-, lähi-infraa vastaava 1064 nm- sekä pidempiaaltoista infrapunasäteilyä vastaava 1550 nm:n aallonpituusalue. Näistä lähi-infran kanava vastaa perinteisesti laserkeilauksessa käytettyä kanavaa. Tämän tutkimuksen tavoitteena oli löytää keino taimikoiden puuston kokonaisrunkoluvun ja havu- ja lehtipuiden runkoluvun sekä edellä mainittujen pituuden määrittämiseen laserkeilaus- ja hyperspektridataa sekä taimikoista mitattuja referenssikoealoja hyväksi käyttäen. Tavoitteena on, että suurin osa maastokartoituksista voidaan tulevaisuudessa korvata tällä menetelmällä. Laadittujen mallien pohjalta määritetyillä puustotunnuksilla voidaan edelleen tulevaisuudessa tehdä hoitotoimenpide-ehdotuksia.

Taulukko 10. Titanin ja kolmen muun yleisesti käytetyn sensorin ominaisuudet. Taulukossa esitetyistä tärkeimmät tämän työn kannalta ovat aallonpituus (eng. wavelength) ja pulssien määrä neliömetrillä (eng. emission sample density).

Parameters	Sensor or Mission Values					
Sensor model	Aquarius	Gemini	Orion C		Titan	
Date	22/07/13	24/08/13	22/07/13		02/07/15	
Wavelength (nm)	532	1064	1550	532	1064	1550
PRF (kHz)	50	70	125	100	100	100
Pulse width (ns)	8	12	2.6		n/a	
Pulse energy (μ J)	70	97	18		n/a	
Peak pulse power (kW)	8.8	8.1	6.9		n/a	
Divergence (1/e) (mRad)	0.7	0.25	0.22	0.7	0.25	0.22
Receiver aperture diameter (m)	0.05	0.05	0.05		0.075	
FOV (deg)	30	40	30		30	
Altitude (km agl)	0.9	1	0.9		1.07	
Emission sample density (pts m ⁻²)	1.5	1.4	2.7	3	3	3
Footprint area (m ²)	0.31	0.05	0.03	0.44	0.06	0.04
Intensity range (bits)*	12	12	12		12	

Mallien selitysasteet, absoluuttiset ja suhteelliset RMSE:t, harha ja sen keskihajonta, kaksisuuntaisen t-testin arvo, df-luku sekä t-testin p-arvo on esitetty taulukossa 5. Runkolukumallien selitysasteet olivat alimmillaan lehtipuumallissa 11,7 % ja parhaimmillaan havupuumallissa 32,7 %. Kokonaisrunkolukumallin selitysaste oli 19,7 %. Harhan keskihajonta oli sekä lehtipuiden runkoluvussa sekä kokonaisrunkoluvussa lähes sama, hieman yli 1700 runkoa/hehtaari, kun se havupuiden runkolukumallissa oli noin tuhat vähemmän. Ero selittyy havupuiden määrän pienuudella lehtipuiden selkeästi keskimäärin suurempaan runkolukuun nähden. Pituusmalleissa lehtipuumalli oli selitysasteeltaan niin ikään heikoin (52,9 %), kun kokonaispituusmallin selitysaste oli 77,2 % ja havupuumallin 64,1 %. Mallien selitysaste vaihtelee paljon, mutta pituusmalleissa se on huomattavasti runkolukumalleja parempi.



Kuva 20. Puuston jakautuminen kuviolla 32. Korkeimmalta, eli pisimmistä puista tulevat kaiut ovat punaisia, oransseja ja keltaisia. Pienemmistä, alle 5 metrin pituisista puista tulevat kaiut on visualisoitu vihreällä. Siniset pisteet kuvantavat maanpinnasta tulevia kaikuja.

Taulukko 11. Tunnusluvut malleittain. n =runkoluku ja h =pituus.

	n_kok	n_havupuu	n_lehtipuu	h_kok	h_havupuu	h_lehtipuu
Mallin selitysaste	19,7	32,7	11,7	77,2	64,1	52,9
RMSE	1734	770	1713	0,91	1,16	1,38
RMSE-%	33,7	32,4	62,0	26,2	33,9	50,1
Harhan keskihajonta	1743	774	1722	0,91	1,16	1,39
Mallin Harha	0	0	0	0	0	0
2 suuntainen t-testi	-5E-14	8E-15	-2E-14	0E+00	1E-14	-2E-14
df	130	150	116	185	179	172
p-arvo	1	1	1	1	1	1

Mallien hyvyttä arvioitaessa tärkein taulukossa esitetyistä tunnusluvuista on RMSE. Suhteelliseksi muutettuna se mahdollistaa tulosten keskinäisen vertailun oman ja muiden tutkimusten välillä. Selitysasteen tapaan suhteellinen RMSE pituusmalleissa on vastaavan ositteen runkolukumalleja parempi, eli alhaisempi. Runkolukumallien suhteellinen RMSE hyvyysjärjestyksessä; havupuu 32,4 %, kokonaisrunkoluku 33,7 % ja lehtipuu 62,0 % sekä vastaavasti pituusmallit; kokonaispituus 26,2 %, havupuu 33,9 % ja lehtipuu 50,1 %. Mallit ovat harhattomia, minkä kaksisuuntainen t-testi vielä todistaa. Taulukon suure df kertoo t-testin vapausasteiden lukumäärän. Jokaisen t-testin p-arvo on nollahypoteesin mukaisesti tasan 1, eli mallin ja mitattujen arvojen keskiarvoissa ei ole eroa.

Kalibrointitutkimus

Taimikoiden runkoluvun ja puulajisuhteiden Lidar perusteinen kalibrointitutkimus toteutettiin aluksi Päijät-Hämeessä standardilla laserkeilausaineistolla. Aineistolla testattiin kolmea eri tapausta:

- 1) VMI-perusteista mallia, jota voidaan soveltaa ilman ulkopuolisia kk-aineistoja (NFI)
- 2) Kaukokartoitusperusteista mallia (RS)
- 3) Edellisten mallien yhdistelmää (BLUP)

Ennustettavia tunnuksia olivat lehtipuiden runkoluku (BN) ja pituus (BH), sekä havupuiden runkoluku (CN) ja pituus (CH).

Tutkimuksessa tuotettiin "Seemingly unrelated regression" -yhtälöt (SURE). Kalibrointiin käytettiin parasta lineaarista harhatonta ennustusmenetelmää ('best linear unbiased prediction', BLUP). Aineiston uudelleen otannan menetelmiä käytettiin ('bootstrapping') ennusteiden luotettavuuden arviointiin.


Tutkimusosion eteneminen 2018

Taimikoiden runkoluvun ja puulajisuhteiden kalibroitimenetelmää useilla eri konsepteilla ja aineistoilla. Biometrisillä malleilla päästään pituuden suhteen 59-75% RMSE tarkkuuteen ja runkoluvun suhteen 65-115% RMSE tarkkuuteen. Lidar aineistolla päästään pituuden suhteen 28-52% RMSE tarkkuuteen ja runkoluvun suhteen 32-92 % RMSE tarkkuuteen. Kalibroidulla aineistojen Yhteiskäytöllä tulokset paranivat 1-2% (Taulukko 12).

Taulukko 12. Suhteelliset luotettavuustunnukset eri aineistoilla (Päijät-Häme, Liperi) ja menetelmillä.


RMSE, %	N, havupuut	N, lehtipuut	H, havupuut	H, lehtipuut
NFI, Päijät-Häme	73,6	115,7	71,2	75,4
Kalibroitu NFI, Päijät-Häme	67,1	112,5	70,4	73,0
NFI, Liperi2	65,4	86,6	59,5	78,8
Kalibroitu NFI, Liperi2	64,9	86,1	58,1	77,6
ALS+IK, Päijät-Häme	42,9	92,5	28,0	36,4
Kalibroitu Päijät-Häme	39,6	92,2	26,4	36,7
Monikanava, Liperi1	32,4	62,0	33,9	52,9
Monikanava, Liperi2	41,1	65,3	45,0	26,6
Kalibroitu RS, Liperi2	40,4	64,7	45,0	26,5

Eri aineistojen ja tunnusten luotettavuuksien hajontaa esitetään Kuva 21, jonka havainnollistaa kohde aineistojen vaihtelua ja vaikeustekijöiden vaikutusta arvioinnin lopputulokseen. Lehtipuiden runkoluvun arviointi on erittäin epäluotettavaa myös Lidar aineistosta. Toisaalta pituusarviot antavat mahdollisuuden luotettavampaan tarkasteluun.



Kuva 21. Eri aineistojen ja taimikon runkoluku (N) ja pituustunnusten (H) luotettavuuksien hajonta.

Lähtökohtaisesti taimikon kehityksen kannalta n. 1 m pituusero kasvatettavan ja raivattavan kasvillisuuden välillä takaa riittävän etumatkan stabiilin metsikön uudistamisen kannalta. Liperin aineistosta tehtiin regressiomalli puulajeittaiselle pituuserolle. Tällöin mallin selitysaste oli kohtuullinen 0.4721 (adjusted R²: 0.4484) (ks. Kuva 22).



Kuva 22. Havaitun pituuseron (x-akseli) ja ennustetun pituuseron (y-akseli) suhde Liperin taimikoissa.

Jos pituusero mallin perusteella simuloidaan taimikonhoidon päätöksentekotilannetta, voidaan mallin ennuste jakaa kahteen luokkaan. Jos pituusero on alle 1 metriä, niin taimikonhoito on tarpeen ja muussa tapauksessa se ei ole tarpeen. Tällöin luokittelu onnistuu erittäin hyvin (Taulukko 13). Aineistosta pystyttiin eliminoimaan n. 20 % vakiintuneita taimikoita. Loput ennustetut ja hoidettavat taimikot sisälsivät myös n. 10% vakiintuneita taimikoita.

Taulukko 13. Pituusero-ennusteen luokittelu kahteen päätösluokkaan (Kappa 0,77) Liperin aineistossa.

Pituusero	alle 1 m	yli 1 m	Yhteensä
alle 1m	51	0	51
yli 1 m	5	11	16
Yhteensä	56	11	67

4. Tulosten arviointi – tulosten tieteellinen merkitys ja käytännön sovellettavuus

4.1. Biometrinen mallinnus ja testaus

Biometrinen mallien ja niiden ALS perusteisen kalibroinnin kanssa saatiin varsin hyviä tuloksia kahdella testialueella, Päijät-Hämeessä ja Liperissä. Käytännön kannalta paras vaihtoehto olisi koko maan kattavien biometrinen mallien käyttö yhdessä ALS perusteisen kalibroinnin kanssa. Koko maan kattavissa vmi11 malleissa oli mukana sekä kivennäismaiden että turvemaiden taimikot. Huomionarvoista oli, että näissä malleissa oli hyvin vähän turvemaiden ominaisuuksia kuvaavia tunnuksia. Vain ”täydellisen tiedon” mallissa oli mukana ”Turvemaadummy”-muuttuja kokonaisrunkoluvun ennusteessa. Kosteusindeksit ja kasvupaikan viljavuus olivat kivennäis- ja turvemaille yhteisiä muuttujia (metsätyyppi rinnastus turvekankaille). Taimikoiden tiheyttä kuvaavien mallien luotettavuustunnukset olivat kuitenkin varsin vaatimattomia. Tämä johtunee siitä, että aineistona oli kaikki vmi11 aineiston pienet ja varttuneet taimikot eli valtava kirjo erilaisia taimikkokohteita. Jos taimikkotutkimus olisi rajattu varttuneisiin taimikoihin, niin keskivirheet olisivat luonnollisesti pienempiä. Toisaalta pienet taimikot ovat tärkeitä varhaisperkauksen tarpeen kannalta. Ongelmana on, että ne ovat vaikeimmin ennustettavia ja hankalasti kalibroitavissa ALS-tunnuksilla. Esim. Næsset ja Bjerknes (2001) löysi vain yhden merkitsevän ALS tunnuksen taimikon tiheyden ennustamiseksi. Kosteusindeksin ja metsätyyppin välillä oli selvä laskeva trendi parhaista kasvupaikoista puolukkatyyppiin. Kuitenkin kuivimmat CT ja CIT kasvupaikat saivat systemaattisesti suurimpia TWI arvoja. Syytä on vaikea arvioida. Se voi johtua pienipiirteisestä vaihtelusta. Esimerkiksi harvinaiset CIT kasvupaikat näyttivät osuvan lähelle ojitettuja soita. Järvenpää (2016) korvasi TWI-muuttujan topografisilla (laki, ylärinne, alarinne, jne.) muuttujilla. Vmi11 aineistossa topografiset luokat korreloivat hyvin voimakkaasti TWI:n kanssa. Kosteusindeksien TWI ja DTW selitysvoimaan oli ladattu paljon odotuksia, mutta niiden merkitys jäi aika marginaaliseksi. Jäi vielä selvittämättä, olisiko hienompi resoluutio TWI:n laskennassa antanut parempia tuloksia. Sen sijaan tieto metsänuudistamisketjusta osoittautui varsin tärkeä. Istutus, kylvö ja luontainen uudistaminen erosivat toisistaan niin taimikon tiheyden kuin pituuskehityksen osalta. Myös tieto maanmuokkauksesta ja etenkin muokkaamattomuudesta oli tärkeä tieto samasta syystä.

4.2. Taimikon ominaisuuksien arviointi eri kaukokartoitusmateriaalien avulla

Lentokone ja drone kuvausten käytännön sovellutuskelpoisuus


UAV:sta kuvattu RGB-pistepilvien ja hyperspektridatan yhdistelmä sekä helikopterista kuvattu ALS Titan – aineisto tuottivat melko tarkkoja estimaatteja taimikoiden tiheydelle ja pituudelle (RMSE tiheydelle n. 20% ja pituudelle n. 10%). RGB-pistepilvien ja hyperspektridatan yhdistelmä ja pelkkä ALS-Titan –data tuottivat suurinpiirtein yhtä hyviä tuloksia tiheyden ja pituuden osalta. Sekä RGB-pistepilvien että ALS –aineiston avulla on mahdollista mitata melko hyvällä tarkkuudella lehtipuiden ja havupuiden (istutettavien / kasvatettavien) puiden pituuseroa.

UAV- pistepilvien ja hyperspektridatan osalta lehdelliseen aikaan tehty kuvaus toimi paremmin sekä tiheys (RMSE% 20%) että pituusmittauksissa (RMSE%= 11.5%).

Laserkeilauksen tapauksessa on kyse suorasta mittauksesta ja tulokset ovat erittäin lupaavia.

Satelliittiperusteisten tulosten käytännön sovellutuskelpoisuus

Hankkeen tulosten perusteella Suomen metsäkeskus on aloittanut operatiivisen vesakkokartoituspalvelun metsänomistajille. Palvelussa erotetaan Metsävaratiedoista taimikot ja luokitetaan ne indeksin avulla vesakkohaitan mukaan (Kuva 23). Tulos toimitetaan metsänomistajille (Kuva 24).



Kuva 23. Kahden taimikon vesoittuneisuusluokitus lisättyinä Metsäkeskuksen Metsävaran kuviotiedoilla. Metsäkeskuksen palvelussa tulos on tätä pelkistetympi.

Indeksin käytössä tunnistettiin muutamia virhelähteitä. Rehevimpien kasvupaikkojen kuusikot, sekä kuuselle istutetut pellot, joissa ei ole perkaustarvetta, saattoivat luokitua kaikkein korkeimpia vesoittuneisuusasteita edustaneisiin luokkiin. Samanlainen virhetulkinta havaittiin osassa turvemaan taimikoita. Parhaan tuloksen saamiseksi satelliittikuvat tulisi saada ennen lehtien kellastumisen alkamista ja täyden lehden aikaan, mikä maan eteläosissa tarkoittaa juhannuksen ja elokuun lopun välistä ajanjaksoa. Mikäli joudutaan käyttämään kuvia tämän ajanjakson ulkopuolelta, NDVI-indeksin luokkarajoja voidaan joutua muuttamaan.




Metsäkeskus on tuottanut tietoa varhaishoitoa tarvitsevista taimikoista Metsään.fi-palveluun.

27.5.2019

Kuva 24. Kuvakaappaus Suomen metsäkeskuksen sivustolta.

<https://www.metsakeskus.fi/uutiset/taimikoiden-varhaishoitokohteet-nakyvat-nyt-metsaanfi-palvelussa>

Nykyisessä Metsäkeskuksen toteutuksessa taimikoiden rajausta saadaan Metsävaratiedoista eli satelliittikuvatulokinnon ulkopuolelta. Taimikoiden erottaminen ja niiden tilan arviointi satelliittikuvista on mahdollista kunhan taimikoiden kehitystä seurataan säännöllisesti päätehakkuusta lähtien (Kuva 25).



Kuva 25. Metsien uudistamisvaiheen seurantajärjestelmä. Ilmak. = ilmakuva, omav. = omavalvonta. Oranssinruskea nuoli - satelliittikuvat olennainen tietolähde, oranssi nuoli - satelliittikuvien hyödyllisyys edellyttää lisäselvityksiä, harmaa nuoli - Sentinel-2 -satelliittikuvien hyöty epävarma. Lähde: Taimikoiden vesoittuneisuuden arviointi satelliittikuvista drone-aineiston avulla, VTT:n tutkimusraportti VTT-CR-06782-18.

VTT:n satelliittikuvaperusteisten tulosten tieteellistä hyödyntämistä rajoittaa edustavan verrokkiaineiston puute. Hankkeessa luotiin menettelyjä luotettavan verrokkiaineiston hankkimiseen, mutta niitä pitäisi kehittää edelleen. Eri puolilla Etelä-Suomea tehdyt kokeet viittasivat siihen, että samat indeksin raja-arvot toimivat keskikesän kuvissa ilman, että kuvia olisi kalibroitu ilmakehäkorjauksen avulla. Kokeita tehtiin kuitenkin niin vähän, että varmuutta NDVI-luokkarajojen rajojen yleispätevyydestä ei voitu saada.

Aineistosta jäi vaikutelma, että nykyiset, koealoihin perustuvat taimikkojen arviointimenetelmät eivät työläydestään huolimatta aina anna edustavaa kuvaa taimikon tilasta taimikoiden sisäisen heterogeenisuuden vuoksi. Koealojen käyttöä satelliittikuvantulkinnan opetusaineistona rajoittaa myös paikannuksen epätarkkuudet.

4.3. Yhteenveto osahankkeista

Yhteenvetona voidaan todeta seuraavaa:

1. Koko Suomen satelliittitulkinta ja biometrinen malli erillisenä ja yhdistettynä
 - a. Uudistamisen ajankohta saadaan luotettavasti satelliittiaikasarjasta
 - b. Biometrinen malli epävarma ($RMSE=60-100\%$), mutta tehtävissä kustannustehokkaasti kaikkialle.
 - c. Satelliittiperusteinen vesakkoisuus indeksin ja runkoluvun relaatio ($R^2 = 0,2-0,3$) on melko epävarma, mutta paikalliset suhteelliset erot selviävät kasvillisuuden osalta.
 - d. Vesaikkoisuuden kehitys seurattavissa satelliittiaikasarjasta osittain
2. Tarkemmat materiaalit otetaan käyttöön aineiston saatavuuden mukaan ja käytetään usein rajatun pienen alueen kontrolliin
 - a. Kokonaisrunkoluku osittain erinomaisesti ($R^2 = 0,8$), ei puulajittaisia testejä
 - b. Kokonaisrunkoluku $RMSE=20\%$, ja pituus $\approx 10\%$
3. Normiresoluutio ALS & biometrinen mallinen erikseen ja yhdistettynä on käyttökelpoinen, kun aineistoa on saatavilla osana muuta inventointia.
 - a. Havu ja lehtipuun pituuden eron mallinnus lupaava ($R^2 = 0,4$) (luokitus Kappa $\approx 0,77$) ja ennustaa suoraan taimikonhoidon tarvetta.
 - b. Puulajittaiset runkoluvut vaativat laserkeilauksen ($R^2(h)=0,5-0,8$, $R^2(n)=0,2$)
 - c. Tulosten puulajittaiset keskivirheet ovat kohtuullisia ($RMSE=30-60\%$), joka tarkoittaa, että aineiston käyttö parantaa ennusteita merkittävästi.

Lupaavin luotettava menetelmä on havu ja lehtipuun pituuseroon keskittyvä Lidar-perusteinen malli. Jos sen perusteella simuloidaan taimikonhoidon päätöksentekotilannetta, niin luokittelu onnistuu erittäin hyvin. Aineistosta pystyttiin identifioimaan vakiintuneet taimikoit ilman hoidettavia kohteita. Loput ennustetut ja hoidettavat taimikot sisälsivät myös n. 10% vakiintuneita taimikoita.

Menetelmien käyttö riippuu paljolti olemassa olevasta aineistosta. Taimikkotiedon tuotanto kannattaa suunnitella siten, että biometrinen mallinnus on tuotettu pohja-aineistoksi ja estimaatteja tarkennetaan riippuen käytettävissä olevista lentokone/drone pohjaisista tiedoista. Satelliittiestimaateilla kannattaa seurata uudistamisajankohtaa ja pahimpia vesoittumiskohteita.

Tutkimus antoi uutta tietoa laajasti eri menetelmistä. Kerätyistä aineistoista pystytään vielä laskemaan käyttökelpoisia tuloksia seuraavissa hankkeissa. Tämän hankkeen resurssit olivat yhtä teknologiaa ja menetelmää kohti rajalliset. Kuitenkin Luken mallit tulevat hankkeen myötä käyttöön ja kaukokartoitusmenetelmien testit demonstroivat ansiokkaasti menetelmällisiä vaihtoehtoja.

5. Julkaisut

Tutkimuskokonaisuuden julkaisut ovat pääosin työn alla. Koska aihepiiriin liittyvää työtä tehdään myös muissa hankkeissa, niin hankkeen aineistoja on esitelty osana aiempaa tutkimusta.

Osahankkeessa 1 demonstraatiokohteelle tehtävä mallinnus ja testaus raportoidaan kansainvälisessä sarjassa. Raportti on vasta käsikirjoitus. Vmi11 aineistoon perustuva taimikonhoitotarpeen ja sen ajankohdan ennustamisesta valmistui yksi pro-gradu.

Aiheen eri osia on esitelty mm. seuraavissa julkaisuissa:

- Miina, J., Turunen, J., Korhonen, K.T., Strandström, M., Ahola, A. 2018. Predicting the need for tending of conifer seedling stands in southern Finland. *Scandinavian Journal of Forest Research* 33(7): 641-649.
- Honkavaara, E., Hakala, T., Nevalainen, O., Viljanen, N., Rosnell, T., Khoramshahi, E., Näsi, R., Oliveira, R and A. Tommaselli. 2016. Geometric and reflectance signature characterization of complex canopies using hyperspectral stereoscopic images from UAV and terrestrial platforms. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 77-82. <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLI-B7/77/2016/isprs-archives-XLI-B7-77-2016.pdf>
- Näsi, R., Honkavaara, E., Tuominen, S., Saari, H., Pölönen, I., Hakala, T., Viljanen, N., Soukkamäki, J., Näkki, I., Ojanen, H. and J. Reinikainen. 2016. Uas Based Tree Species Identification Using the Novel FPI Based Hyperspectral Cameras in Visible, NIR and SWIR Spectral Ranges. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1143-1148. <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLI-B1/1143/2016/isprs-archives-XLI-B1-1143-2016.pdf>
- Näsi, R., Honkavaara, E., Lyytikäinen-Saarenmaa, P., Tuominen, S., Blomqvist, M., Litkey, P., Hakala, T., Viljanen, N., Kantola, T., Tanhuanpää, T. & Holopainen, M. 2016. Using frame format hyperspectral cameras for forest applications - healthy and tree species mapping. Poster presentation in ISPRS summer school, Presidente Prudente, Brazil.
- Markelin, L., Honkavaara, E., Näsi, R., Viljanen, N., Rosnell, T., Hakala, T., Vastaranta, M., Koivisto, T., and Holopainen, M. 2017. Radiometric correction of multitemporal hyperspectral UAS image mosaics of seedling stands, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLII-3/W3, 113-118, <https://doi.org/10.5194/isprs-archives-XLII-3-W3-113-2017>, 2017.
- Piispanen, Joonas. 2017. Taimikon tiheyden ja pituuden arviointi laserkeilauksen ja numeeristen ilmakuvien avulla. Itä-Suomen yliopisto, luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto. Metsätieteen kandidaatin tutkielma. 32 s.
- Manninen, Pekka. 2017. Monikanavalaserkeilaus taimikon puustotunnusten määrittämisessä. Itä-Suomen yliopisto, luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto, metsätieteiden kandidaatin tutkielma. 36 s.
- Mattila, U., Mehtätalo, L., Siipilehto J., Rana, P., Hou, Z., Tokola, T. 2019. Data fusion of biometric models and multispectral ALS data in forest seedling stand monitoring. Manuscript.
- Muinonen, E., Vastaranta, M., Tokola, T.. 2019. Controlling Quality of Forest Regeneration Stands using Landsat Time Series. Manuscript.
- Turunen, J. 2017. Taimikonhoitotarpeen ja sen ajankohdan ennustaminen männyn, kuusen ja koivun taimikoissa Etelä-Suomessa valtakunnan metsien inventointiaineiston avulla. Itä-Suomen yliopisto, luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto, metsätieteiden kandidaatin tutkielma. Pro gradu, erikoistumisala metsien hoito ja metsäekosysteemit. 51 sivua
- Zhengyang Hou, Qing Xu, Lauri Mehtätalo, Jouni Siipilehto, Jonathan A. Greenberg, Timo Tokola 2017. Improve young stands inventory through calibration with remote sensing and best linear unbiased prediction. *Silvilaser 2017*, accepted Abstract.
- Zhengyang Hou, Qing Xu, Lauri Mehtätalo, Jouni Siipilehto, Parvez Rana, Timo Tokola 2017. Improve young stands inventory through calibration with remote sensing and best linear unbiased prediction. Manuscript.

VTT:n julkaisut ovat käsikirjoitusvaiheessa. Tämän raportin lisäksi drone-osahankkeesta kirjoitettiin raportti "Taimikoiden vesoittuneisuuden arviointi satelliittikuvista drone-aineiston avulla", joka toimitettiin Metsäkeskukseen (VTT:n tutkimusraportti VTT-CR-06782-18).

Kirjallisuus

Escuin S., Navarro, R., Fernandez, P. 2008. Fire severity assessment by using NBR (Normalized Burn Ratio) and NDVI (Normalized Difference Vegetation Index) derived from LANDSAT TM/ETM images. *Journal International Journal of Remote Sensing*, 29 (4):1053-1073.

Järvenpää, J. 2016. Kuusen varhaiskehitys 3-15- vuotiailla kääntömätästyskohteilla – Maaso- ja paikkatietoaineistoihin perustuva pituuskehityksen mallinnus. Pro gradu tutkielma. Helsingin yliopisto. Maatalous-metsätieteellinen tiedekunta, Metsätieteen laitos. 60 s.

Key, C. H. & Benson, N.C. 2006. Landscape assessment (LA) FIREMON: fire effect monitoring and inventory system. In: Lutes, D.C. Keane, R.E., Carati, J.F., Key, C.H., Benson, N.C., Gangi, L.J. (Eds.), General Technical report RMRS-GTR-164-CD. USDA Forest Service, Rocky Mountains Research Station, Fort Collins, CO (pp.1-55).

Korhonen L., Pippuri I., Packalén P., Heikkinen V., Maltamo M., Heikkilä J. Detection of the need for seedling stand tending using high-resolution remote sensing data. *Silva Fennica* vol. 47 no. 2 article id 952

Næsset, E., Bjerknes, K.O., 2001. Estimating tree heights and number of stems in young forest stands using airborne laser scanner data. *Remote Sensing of Environment* 78: 328–340.

Suvanto A., Maltamo M., Packalén P., Kangas J. 2005. Kuviokohtaisten puustotunnusten ennustaminen laserkeilauksella. *Metsätieteen aikakauskirja* 4/2005: 413-428.