

Kaukokartoitus mahdollistaa tarkan tiedon tuottamisen metsäluonnon monimuotoisuutta ilmentävistä piirteistä

SONJA KIVINEN¹ & TOPI TANHUANPÄÄ^{1&2} & ARTO VIINIKKA^{3&4} & JANNE MÄYRÄ⁴ & SARITA KESKI-SAARI¹ & ANTON KUZMIN¹ & PEKKA HURSKAINEN⁴ & IDA PALMROOS⁵ & EINARI HEINARO¹ & PASI KORPELAINEN¹ & PETTERI VIHHERVAARA⁴ & TIMO KUMPULA¹
Itä-Suomen yliopisto¹ & Helsingin yliopisto² & Maanmittauslaitos³ & Suomen ympäristökeskus⁴ & Ympäristöministeriö⁵



Kivinen, Sonja & Tanhuanpää, Topi & Viinikka, Arto & Mäyrä, Janne & Keski-Saari, Sarita & Kuzmin, Anton & Hurskainen, Pekka & Palmroos, Ida & Heinaro, Einari & Korpelainen, Pasi & Vihervaara, Petteri & Kumpula, Timo (2024) Kaukokartoitus mahdollistaa tarkan tiedon tuottamisen metsäluonnon monimuotoisuutta ilmentävistä piirteistä (Remote sensing reveals detailed information on forest biodiversity features). Terra 136(4) 181–196. <https://doi.org/10.30677/terra.143654>



Up-to-date knowledge of key ecological features that maintain boreal forest biodiversity is essential part of sustainable forest management and conservation measures. However, there is only a limited amount of spatial data available, as the detection of ecologically significant elements using remote sensing is challenging due to their low frequency, scattered occurrence, small size and/or location in the field layer. We studied tree-level discrimination of the keystone species aspen (*Populus tremula* L.) from other common tree species and detection of deadwood utilizing airborne high-resolution RGB images, multispectral and hyperspectral data and airborne laser scanning (ALS) data. We also tested the predictive accuracy of remote sensing parameters in predicting the aspen epiphytic lichen communities. Our results demonstrate that high-resolution remote sensing data together with machine learning algorithms provide new possibilities for mapping the occurrence and spatial distribution of key ecological features and producing proxies of biodiversity. It should be noted that field work is also needed for model training and evaluation. Moreover, resources and collaboration of different organizations are needed for biodiversity assessment and monitoring over large geographical areas.

Key words: aspen, biodiversity, boreal forest, deadwood, remote sensing

Sonja Kivinen, Historia- ja maantieteiden laitos, Itä-Suomen yliopisto, PL 111, FI-80101 Joensuu, Finland. E-mail sonja.kivinen@uef.fi.

Monimuotoisen metsäluonnon säilyttäminen edellyttää tietoa lajien ja erilaisten elinympäristöjen esiintymisestä ja levinneisyydestä sekä ekosysteemien rakenteesta ja toiminnasta. Metsäekosysteemit ovat jatkuvassa muutoksessa niin maailmanlaajuisesti kuin Suomessakin, mikä on seurausta metsätalouteen, maankäytön muutoksiin ja ilmastomuutokseen liittyvistä tekijöistä (Esseen ym. 1997; Gauthier ym. 2015). Ajantasaisen, mahdollisimman kattavan ja edustavan tiedon avulla voidaan arvioida, miten metsäekosysteemit reagoivat erilaisiin ympäristömuutoksiin. Lisäksi voidaan arvioida luontokadon voimakkuutta ja suuntaa pitkällä aikavälillä sekä suunnitella, millaisia toimenpiteitä tarvitaan metsäekosysteemin säilyttämiseksi ja monimuotoisuuden turvaamiseksi tuleville sukupolville (Larsson & Danell 2001; Forsius ym. 2021; Berner ym. 2022; Virkkala ym. 2022; Alam ym. 2023).

Suomella on useita luonnon tilan seurantavelvoitteita, joista monet koskevat myös metsäelinympäristöjä. Näihin kuuluvat esimerkiksi toistuvat kansainväliset arvioinnit hallitustenväliselle luontopaneelille (IPBES) sekä kansainvälisten ympäristösopimusten ja EU:n edellyttämät raportoinnit (muun muassa Kansainvälisen biodiversiteettisopimuksen sekä EU:n luonto- ja lintudirektiivin raportit), jotka määräajoin kokoavat tutkijoiden ja asiantuntijoiden uusimmat luontotiedot yhteen. Metsiin liittyviä uusia ja tulevia velvoitteita ovat esimerkiksi EU:n biodiversiteettistrategia (Ympäristöministeriö 2024), luonnon ennallistamisasetus (European Commission 2024) sekä ympäristötilinpidon asetuksen laajennus, joka tulee kattamaan muun muassa metsä- ja ekosysteemitilinpidon. Nämä seurantavelvoitteet edellyttävät koko EU:n kattavia yhtenäisiä menetelmiä ja indikaattoreita luonnon tilan seurantaan

elinympäristöittäin, joista on laadittu viime aikoina ehdotus (Vallecillo ym. 2022).

Tieto metsäluonnon piirteistä, jotka ylläpitävät monimuotoisuutta on välttämätöntä tehokkaiden suojelutoimien ja kestävänsä metsänhoidon toimenpiteiden suunnittelussa (Valbuena 2015; Adnan 2020; Čosović ym. 2020; Oettel & Lapin 2021; Hekkala ym. 2023). Elävä ja kuollut puusto määrittävät boreaalisten metsien rakenteen ja siten myös laajalti metsäelinympäristöjen ominaispiirteet ja eliöeläinten monimuotoisuuden. Puulajien erot rakenteen, ekofysiologian ja elinkierro-ominaisuuksien suhteen muodostavat monenlaisia elinympäristöjä metsän muille lajeille. Borealisissa metsäekosysteemeissä lehtipuut lisäävät eri lajiryhmien monimuotoisuutta (Kuuluvainen ym. 2004). Avainlajiksi kutsutaan lajia, joka vaikuttaa voimakkaasti ekosysteemin tai eliöyhteisön toimintaan, pysyvyyteen tai monimuotoisuuteen. Avainlajin väheneminen tai häviäminen voi siten aiheuttaa merkittäviä muutoksia muiden lajien elinympäristöön ja säilymiseen (Mönkkönen 2004). Euroopan borealisissa metsissä tärkeä avainlaji on metsähaapa (*Populus tremula* L.), joka esiintyy harvalukuisena, mutta ylläpitää ja hyödyttää satoja muita eliölajeja ravinnonlähteenä tai elinympäristönä. Erityisesti vanhat, järeät haavat ovat merkittäviä monimuotoisen eliöstön kannalta. Tieto avainlajien esiintymisestä metsämaisemassa on oleellista siihen liittyvän eliöeläimistön nykyhetken kuin myös tulevaisuuden monimuotoisuuden tilan arvioinnissa (Kouki ym. 2004; Kivinen ym. 2020).

Elävien puiden lisäksi kuolleet puut ja lahoava puuaines muodostavat tärkeän elinympäristön ja ravinnonlähteen borealisille metsälajeille, ja merkittävä määrä uhanalaisia lajeja elää lahoppuilla. Lahoppuun määrää voidaankin käyttää yhtenä monimuotoisuuden mittarina metsäympäristöissä (Jonsson ym. 2005; Juutinen ym. 2006; Lassauce ym. 2011). Runsaasti lahoppuuta sisältävät vanhat metsät ovat vähentyneet voimakkaasti intensiivisen metsätalouden myötä (Siitonen 2001; Kuuluvainen 2002, Määttänen ym. 2022). EU:n biodiversiteettistrategian mukaan kaikki jäljellä olevat luonnontilaiset ja vanhat metsät (*primary and old-growth forests*) tulee suojella tiukasti EU:n jäsenvaltioissa (Syrjänen ym. 2024). Tämä on herättänyt paljon julkista keskustelua. Juuri valmistuneessa kansallisessa tarkastelussa (Syrjänen ym. 2024) vanhojen metsien osalta pääkriteereiksi eli indikaattoreiksi on ehdotettu seuraavia: luontainen puulajisto, vanhat tai suuret puut, kuolleiden puiden suuri osuus ja lajiston monimuotoisuus. Lisäksi täydentäviä indikaattoreita ovat luontainen uudistuminen, puuston rakenteellinen monipuolisuus, habitaattipuut ja vanhalle metsälle ominainen indikaattorilajisto, johon voi kuulua uhanalaisia lajeja.

Kaukokartoituksen (*remote sensing, earth observation*) rooliin luonnon monimuotoisuuteen liittyvän tiedon lähteenä on kohdistunut kasvavia odotuksia uusien teknologisten edistysaskelten myötä (Lausch ym. 2016; Vihervaara ym. 2017; Cavender-Bares ym. 2022). Kaukokartoituksella tarkoitetaan tiedon hankkimista maanpinnalta ja maanpinnan yläpuolisista kohteista ilman suoraa fyysistä kosketusta käyttäen esimerkiksi drooniin, lentokoneeseen tai satelliittiin kiinnitettyjä mittalaitteita. Laajemmin ymmärrettynä mukaan voidaan laskea myös maanpinnalta kaukokartoitusmittalaittein tehtävää kartoitusta. Uudessa kaukokartoituksen sovelluksissa maastohavainnointi on myös olennainen osa tiedonkeruuprosessia ja menetelmän tarkkuuden arviointia.

Maanpinnan eri kohteet heijastavat auringon sähkömagneettista säteilyä sen eri aallonpituusalueilta kohteille ominaisilla tavoilla, ja näitä eroavuuksia hyödynnetään kohteiden tunnistamisessa ja erottamisessa toisistaan (Jensen 2000). Auringon valoa hyödyntävät passiiviset kaukokartoitusmenetelmät ovat merkittävässä roolissa esimerkiksi luonnon monimuotoisuuden seurantojen harmonisoimiseksi kehitetyissä keskeisissä biodiversiteetti-indikaattoreissa (*essential biodiversity variables, EBV*) (Pereira ym. 2013). EBV-indikaattorit perustuvat tyypillisesti satelliittikuva-aineistoihin, jotka kattavat laajoja maantieteellisiä alueita (Reddy 2021). Monet ehdotetuista EBV-indikaattoreista ovat tietotarpeiltaan yhteneväisiä edellä mainittujen raportointivelvoitteiden kanssa, mutta ne eivät tarjoa tietoa ekologisesti merkittävistä pienimuotoisista piirteistä (Skidmore ym. 2021).

Korkean spatiaalisen tai spektrisen erotuskyvyn omaavien kaukokartoitusaineistojen yleistymisen on mahdollistanut entistä tarkemman tiedon tuottamisen erilaisista maanpinnan kohteista (Vihervaara ym. 2019). IBC-Carbon-hankkeen (2018–2023, Strategisen tutkimuksen neuvosto) tavoitteena oli metsien biodiversiteetin, hiilen varastoinnin ja sidonnan sekä muiden ekosysteemipalveluiden yhteen nivoutuva suojelu, tiedon lisääminen ja menetelmien kehittäminen sekä päätöksentekoon vaikuttaminen. Hankkeen kaukokartoitusosassa tarkasteltiin muun muassa eri kaukokartoitusaineistojen soveltuvuutta arvokkaiden metsäluonnon piirteiden ja lajien esiintymisen kartoittamisessa.

Tässä artikkelissa esitämme synteysin metsäelinympäristöissä kaukokartoituksen keinoin tehdyn tutkimuksemme tuloksista ja pohdimme havaintojamme monimuotoisuustiedon tuottamisesta aihepiiriin liittyvän viimeaikaisen tutkimuksen valossa. Tavoitteenamme oli tuottaa tietoa siitä, miten ja millä tarkkuudella borealisen metsäluonnon avainlaji haapa ja toisaalta ekologisesti tärkeä laho-

puu voidaan erottaa metsämaisemasta kaukokartoitusmenetelmien avulla. Kaukokartoitusaineistojen soveltuvuutta lajirikkauden ja lajiyhteisöjen ennustamisessa tarkasteltiin käyttämällä haavan rungolla eläviä epifyyttijäkäläiä esimerkkiaineistona.

Kaukokartoitusmenetelmien uudet mahdollisuudet metsäluonnon monimuotoisuustiedon tuottamisessa

Kaukokartoitusmenetelmät ovat kehittyneet voimakkaasti 2000-luvun aikana ja esimerkiksi metsävaratiedon tuottamisessa on siirrytty metsikkökuvioiden maastomittauksista kaukokartoituspohjaisiin menetelmiin. Kaukokartoituspohjainen metsävaratieto tuotetaan tyypillisesti kuviotasolla (Packalén & Maltamo 2007). Metsävarakuviot on toimenpidetarpeiltaan, kasvupaikaltaan ja puustoltaan yhtenäinen metsäalue. Kuviotasoa käytetään taloudellisesti merkittävän puuston ominaisuuksien kartoittamiseen. Siirtyminen kaukokartoituspohjaisiin menetelmiin onkin jättänyt metsäluonnon ekologeisista piirteistä kerättävän tiedon kehittämisen vähäiselle huomiolle aina viime vuosiin saakka (Suomen Metsäkeskus 2021; Tanhuanpää ym. 2023). Nykyisin tuotettava metsävaratieto ei erottele lehtipuita toisistaan, vaan kuviokohtainen puustoa kuvaava tieto on saatavana männyille, kuusille ja yleisesti lehtipuulle. Tämä on ongelmallista etenkin metsien ekologisen tarkastelun kannalta, jossa tarvitaan erillistä tietoa valtalehtipuulaji koivun ja esimerkiksi huomattavasti harvinaisemman haavan esiintymisestä. Myös lahoppuun esiintymisestä metsäympäristöissä on vain vähän tarkkaa spatiaalista tietoa, sillä valtakunnan metsien inventointi (VMI) tuottaa lahoppuusta yleistettyä tietoa alueellisella tasolla. Operatiivisen metsävaratiedon keräämiseen lahoppu ei sisälly lainkaan tällä hetkellä.

Spatiaaliselta ja spektriseltä erotuskyvyltään tarkat kaukokartoitusaineistot ovat tuoneet uusia mahdollisuuksia metsäluonnon ekologisesti merkittävien piirteiden kartoittamiseen (White ym. 2016; Camarretta ym. 2019). Spatiaalinen erotuskyky (resoluutio) tarkoittaa pienintä kuvassa havaittavaa yksikköä, ja viittaa tyypillisesti yhden kuvapikselin kattamaan alueeseen. Spektrisellä erotuskyvyllä tarkoitetaan kaukokartoitusinstrumentin kykyä havaita pieniä muutoksia säteilyn intensiteetissä eri aallonpituuksilla, toisin sanoen aallonpituusalueiden eli kanavien lukumäärää ja niiden leveyttä (Jensen 2000). Hyperspektrikuvaavassa kaukokartoituksessa tietoa maanpinnan heijastusominaisuuksista tallennetaan jopa sadoilta kapeilta aallonpituusalueilta. Verrattuna muutamia aallonpituusalueita (yleensä kolmesta kymmeneen)

sisältäviin niin sanottuihin multispektriaineistoihin, hyperspektriaineistot mahdollistavat eri kohteiden huomattavasti tarkemman erottamisen ja luokittelun (Im & Jensen 2008).

Korkean spatiaalisen resoluution omaavat aineistot mahdollistavat hyvin yksityiskohtaisten kohteiden tulkintaa, kuten yksittäisten puiden lajinmäärityksen (esim. Schiefer ym. 2020) tai yksittäisten lahoppuiden paikantamisen (esim. Thiel ym. 2020). Hyperspektriaineistojen avulla voidaan tunnistaa esimerkiksi puulajeja ja tarkastella kasvillisuuden biokemiallisia ja biofysikaalisia ominaisuuksia (Dalponte ym. 2012; Croft ym. 2017; Piironen ym. 2017; Sothe ym. 2020). Vastaavasti voidaan tunnistaa tauteja tai tuhoeläimiä varhaisemmassa vaiheessa kuin ihmissilmin ja siten saada tietoa puiden terveydentilasta (Degerickx ym. 2018). Lehtien biokemiallisessa koostumuksessa on lajien välisen vaihtelun lisäksi myös lajin sisäistä vaihtelua. Hyperspektriaineistojen avulla voidaankin tarkastella heijastusominaisuuksien vaihtelua myös saman puulajin eri puuyksilöiden välillä (Deepak ym. 2020). Esimerkiksi Pohjois-Amerikassa kasvavan amerikanhaavan (*Populus tremuloides*) klonaalisesti laajoja kasvustoja muodostavat yksilöt voidaan erottaa toisistaan heijastusspektrin avulla (Madritch ym. 2014). Korkea spatiaalinen tai spektrinen resoluutio tarkoittaa kuitenkin myös suurempaa aineistokokoa, mikä vaatii edistyneitä aineiston käsittelytapoja ja analyysimenetelmiä (Audebert ym. 2019). Erityisesti viime vuosikymmenen aikana syväoppimismenetelmät ovat vakiinnuttaneet asemansa myös kaukokartoitusaineistojen käsittelyssä ja analyysissä, kuten maanpeitetulkinna, hahmontunnistuksessa ja kohteiden luokittelussa (Lary ym. 2016; Ma ym. 2019; Yuan ym. 2020).

Lentolaserkeilauksen (*airborne laser scanning, ALS*) avulla voidaan tuottaa tarkkaa kolmiulotteista tietoa maanpinnan eri kohteista. Lentolaserkeilaus on aktiivinen kaukokartoitusmenetelmä, joka perustuu LiDAR (*light detection and ranging*) -tekniikkaan, jossa mittalaitteen ja mitattavan kohteen välinen etäisyys mitataan laservalon avulla (Wehr & Lohr 1999). Lentokoneeseen sijoitettu laserkeilain lähettää miljoonia laserpulsseja kohti maanpintaa ja muodostaa pulseista tehtyjen etäisyysmittausten avulla kohdetta kuvaavan kolmiulotteisen (3D) pistepilven, jossa jokainen piste sisältää sijaintikoordinaattien lisäksi kohteen korkeustiedon. Pistepilven avulla voidaan muodostaa tarkkoja maanpintaa ja sen päällä olevia kohteita kuvaavia malleja, jotka tarjoavat tietoa esimerkiksi maanpinnan korkeudesta, yksittäisten puiden pituudesta ja latvuksen rakenteesta (Korpela ym. 2010; White ym. 2013). Laserkeilausaineiston tarkkuus riippuu


pistepilven tiheydestä, joka yleisesti määritellään pisteiden lukumääränä pinta-alayksikköä (m²) kohden. Suomessa on saatavana avoimena aineistona koko maan kattava vuosina 2008–2019 kerätty laserkeilausaineisto, joka on pistetiheydeltään noin 0,5 pistettä neliometrillä. Vuonna 2020 alkaneessa toisessa valtakunnallisessa laserkeilauskampanjassa kerättävän laserkeilausaineiston tiheys nostettiin 5 pisteeseen neliometrillä. Pienempialaisista, yksittäisistä kohteista voidaan kuitenkin kerätä huomattavasti tätäkin tarkempia aineistoja, joiden pistetiheys voi olla jopa satoja pisteitä neliometrillä. Tällaiset aineistot mahdollistavat kohteiden erittäin yksityiskohtaisten mallintamisen (Beland ym. 2019; Heinaro ym. 2023).

Droonit (*drones, unmanned aerial vehicle, UAV*) ovat saavuttaneet merkittävän roolin paikallisen tason kaukokartoituksessa, sillä ne mahdollistavat kustannustehokkaan ja joustavan tavan kerätä tietoa erilaisista kohteista. Droonit voidaan varustaa esimerkiksi RGB-kameralla, joka tallentaa näkyvän valon aallonpituuksia tai multispektri- tai hyperspektrikameralla, jotka rekisteröivät näkyvän valon lisäksi myös infrapuna-alueen aallonpituuksia. Aineistojen spatiaalinen erotuskyky on tyypillisesti joitakin senttimetrejä, joten ne ovat huomattavasti satelliiteista tai lentokoneesta saatuja aineistoja yksityiskohtaisempia (Tang & Shao 2015; Adão ym. 2017; Nevalainen ym. 2017; Gini ym. 2018). Droonien avulla voidaan tuottaa myös kolmiulotteista pistepilvitietoa, joka mahdollistaa tarkan, kolmiulotteisen tiedon tuottamisen haluttujen kohteiden rakenteesta (Wallace ym. 2016; Hu ym. 2020). Aineistoja voidaan kerätä toistuvasti samasta kohteesta, mikä puolestaan mahdollistaa muutosten tarkastelun. Droonien avulla kerätyt aineistot kattavat rajallisen alueen, joten ne eivät sovellu laajojen maantieteellisten alueiden tarkasteluun.

Aineistot ja menetelmät

Puulajien tunnistaminen ja haavan klorofyllipitoisuus

Hämeenlinnan Evolla sijaitseva 83 km² laajuinen tutkimusalue (kuva 1) koostuu sekä suojelluista että metsätalouden piirissä olevista metsistä. Suurimmat suojelualueet ovat Kotisten aarnialue ja Sundenpänkankaan suojelualue. Evon tutkimusalue on pinnanmuodoiltaan melko loivapiirteistä eikä huomattavia korkeusvaihteluita esiinny alueella. Pääpuulajit ovat mänty (*Pinus sylvestris* L.), kuusi (*Picea abies* (L.) Karst), rauduskoivu (*Betula pendula* Roth) ja hieskoivu (*Betula pubescens* Ehrh.). Metsähaapa (*Populus tremula* L.) esiintyy alueella harvakseltaan ja laikuittain.



Kuva 1. Evon ja Hiidenportin tutkimusalueiden sijainti. *Figure 1. Location of the Evo and Hiidenportti study areas.*

Evolla toteutettiin mittauskampanja heinäkuussa 2018, jossa kerättiin spatiaaliselta ja spektriseltä erotuskyvyltään korkealaatuisia kaukokartoitusaineistoja, jotka kattoivat koko tutkimusalueen (83 km²). Hyperspektriaineisto sisälsi satoja spektrikanavia näkyvän valon sekä lähi-infrapunan alueilla (405–2500 nm) ja sen spatiaalinen resoluutio oli 0,5–1,0 metriä. Samassa kampanjassa kerättiin myös lentolaserkeilausaineisto, jonka pistepilven tiheys oli keskimäärin 10,2 pistettä/m². Tutkimusalueelta kerättiin myös droonien avulla RGB-, hyperspektri- ja multispektrikuva-aineistoa sekä LiDAR -aineistoa kesinä 2018–2022. Kerättyjen drooniaineistojen spatiaalinen erotuskyky oli 3,9–14,5 senttimetriä ja kuvattujen alueiden pinta-ala oli yhteensä noin 19 km².

Kesällä 2018 alueelta mitattiin yhteistyössä Luonnonvarakeskuksen (Luke) kanssa yhteensä neljä-sataa ympyräkoelaa kaukokartoitusaineistojen vertailuaineistoiksi. Koelajien säde oli yhdeksän metriä ja niiltä määritettiin tiedot puulajista, rinnan-

korkeusläpimitasta ja pituudesta yksittäisen puun tarkkuudella. Koealoilta mitattiin kaikki rinnankorkeusläpimitaltaan yli 4,5 senttimetriä pak-sut puut ja koealojen keskipisteiden sijainnit määritettiin RTK-GNSS-paikannuksen avulla (*real-time kinematic global navigation satellite system*). Haapoja esiintyi koealoilla harvakseltaan, joten edellä mainittujen koealojen lisäksi mitattiin ja paikannettiin yhteensä 599 yksittäistä haapaa. Nämä sijaitsivat sekä suojelualueilla että talousmetsissä. Maastoaineistoa täydennettiin myöhemmin kesinä mittaamalla ja paikantamalla vallitsevasta latvuskerroksesta myös muita puulajeja sekä pystyyn kuolleita puuta.

Haavan erottamista muista yleisistä puulajeista (mänty, kuusi, koivu) tarkasteltiin hyperspektriaineiston ja lentolaserkeilausaineiston avulla. Analyysit tehtiin puutasolla ja tätä varten yksittäisten puiden latvukset tunnistettiin ja rajattiin laserkeilausaineistosta johdetun latvusmallin (0,5 m pikselikoko) ja maastosta kerätyn RTK-GNSS-paikannukseen perustuvan vertailuaineiston avulla. Maastoaineistoon valittiin rinnankorkeusläpimitaltaan yli 15 senttimetriä olevat elävät puut, jotta niiden latvustot erottuisivat ilmasta katsottuna mahdollisimman hyvin. Tämä helpotti maastosta mitattujen puiden yhdistämistä laserkeilausaineistosta rajattuihin puiden latvuksiin. Aineisto sisälsi yhteensä 6599 yksittäistä puuta.

Eri aallonpituusalueiden (455–2500 nm) ja aallonpituusalueista laskettujen pääkomponenttien ja kasvillisuusindeksien roolia puulajien luokittelussa arvioitiin käyttämällä kahta koneoppimismallia – tukivektorikonetta (*support vector machine*, SVM) ja luokittelupuihin perustuvaa satunnaismetsämenetelmää (*random forest*, RF) (Viinikka ym. 2020).

Mallin tarkkuutta arvioitiin käyttämällä opetusaineistosta erillistä testiaineistoa ja erilaisia tilastollisia mittareita. Kokonaisluokittelutarkkuus on yksinkertainen mittari, joka kuvaa oikein luokiteltujen puiden osuutta kaikista testiaineiston puista. Kappa-arvo on tilastollinen suure, joka mittaa, kuinka paljon tarkempi saavutettu luokitus on verrattuna puhtaasti satunnaiseen luokitukseen. Arvo 1 tarkoittaa täydellistä vastaavuutta ja arvo 0 tarkoittaa, että suoritus on satunnaisten arvauksen vertainen. F1-arvon perusteella arvioitiin mallin suorituskkyä yksittäisillä puulajeilla. Mitä suurempi F1-arvo on (vaihteluväli 0–1), sitä parempi mallin suorituskky on kyseisen puulajin osalta.

Samoja aineistoja käyttäen tarkasteltiin kolmiulotteisten konvoluutioverkkojen (*three-dimensional convolutional neural networks*, 3D-CNN) suorituskkyä puulajiluokittelussa verrattuna muihin yleisesti käytettyihin koneoppimismenetelmiin, kuten tukivektorikoneeseen, satunnaismetsään, gradienttivahvistuskoneeseen (*gradient boosting machine*) ja neuroverkkoihin (*artificial neural network*) (Mäyrä ym. 2021). Tutkimuksessa käytettiin hyperspektriaineistosta kaikkiaan 250 spektrikanavaa aallonpituusalueilta 400 nm–1800 nm.

Haapojen tunnistamista yksittäisten puiden tarkkuudella tutkittiin myös droneilla kerätystä aineistosta (ks. kuva 2) (Kuzmin ym. 2021). Tutkimuksessa käytettiin RGB-aineistoja ja niihin pohjautuvia korkearesoluutioisia fotogrammetrisia pistepilviä ja multispektriaineistoja. Yksittäisten puiden latvukset rajattiin pistepilviaineistosta. Erilaisten spektriirteiden merkitystä haavan tunnistamisessa muista puulajeista tarkasteltiin tukivektorikoneeseen perustuvan mallin avulla.



Kuva 2. Evolla sijaitseva suojeltu Kotisten aarnialue dronista kuvattuna heinäkuussa 2019. Kuva: UEF Drone Lab.

Figure 2. Old primeval forest in the protected area of Kotisten aarnialue in Evo detected from the drone in July 2019. Image: UEF Drone Lab.

Klorofyllipitoisuuden vaihtelun tarkastelemiseksi yksittäisistä metsähaapayksilöistä (525 puuta) kerättiin kesällä 2018 latvustosta lehtinäytteet, joista määritettiin klorofyllipitoisuus spektrofotometrisesti. Puuston tiheys laskettiin LiDAR-aineistosta kaikkien puulajien latvusten lukumääränä 30 metrin säteisessä ympyräkoelassa kunkin haavan ympärillä. Klorofyllipitoisuuden ja puuston tiheyden välinen lineaarinen regressio laskettiin erikseen talous- ja suojelumetsien sekä tienvarsien puille (Keski-Saari ym. 2024). Hyperspektiaaineistosta tunnistettiin maastossa paikannettujen koordinaattien perusteella 351 näyteenottohaavan latvustot, ja erotettiin niiden keskiarvospektri. Osittaisen pienimmän neliösumman regressiolla (*partial least squares regression*, PLSR) mallinnettiin klorofyllipitoisuutta hyperspektiaaineiston (432–810 nm) perusteella. Lisäksi tarkasteltiin indeksipohjaisia lähestymistapoja testaamalla kaikki mahdolliset aallonpituuskombinaatiot ja etsimällä niistä parhaat yhdistelmät *random forest* -koneoppimistekniikalla.

Lahopuun kartoittaminen

Hiidenportin tutkimusalue Sotkamossa on laajuudeltaan 16 km² ja koostuu osista Hiidenportin kansallispuistoa ja Teeri-Lososuon soidensuojelualuetta sekä näiden välisestä talousmetsäalueesta (kuva 1). Alueen pääpuulajit ovat runsausjärjestyksessä kuusi, mänty ja koivu, mutta etenkin suojelualueilla esiintyy harvakseltaan myös vanhoja haapoja. Alue on pinnanmuodoiltaan kumpuilevaa ja alavilta osiltaan luonnontilaista tai ojittua suota.

Hiidenportin tutkimusalueella kerättiin tiheä (15 pistettä/m²) lehdettömän ajan lentolaserkeilausaineisto toukokuussa 2019 maalahopuun kartoittamista varten. Tämän lisäksi keilausaluetta täydennettiin erittäin tiheällä (285 pistettä/m²) droonilaserkeilauskella kesäkuun alussa 2020. Kaukokartoitusaineistojen tueksi alueelta mitattiin kesien 2019–2020 aikana yhteensä 185 säteeltään yhdeksän metristä ympyräkoelaa, joilta määritettiin eläviä puita kuvaavien läpimitta-, pituus- ja puulajitunnusten lisäksi kaikkien kuolleiden puiden tarkat sijainnit, läpimitat ja pituudet. Kuolleille pystyville määritettiin tyven sijainti, kun taas maassa makaaville rungoille määritettiin sekä tyven että latvan sijainnit. Mittausten perusteella saatiin muodostettua vertailu- ja opetusaineistoksi yksityiskohtaiset lahopuukartat. Lahopuukartoitusta varten kerättiin droonien avulla myös RGB-, multispektri- ja hyperspektrikuvaineistoja vuosina 2019 ja 2020. Aineiston spatiaalinen resoluutio oli noin 4 senttimetriä ja kuvattujen alueiden pinta-ala oli noin 10 km².

Heinaron ym. (2021) tutkimuksessa maalahopuita tunnistettiin tiheästä laserkeilauksesta Hough-

muunnokseen perustuvan viivantunnistusmenetelmän avulla. Kehitetyn tunnistusmenetelmän yleisen toimintatarkkuuden arvioinnin lisäksi tutkimuksessa tarkasteltiin, miten maalahopuiden ominaisuudet (pituus, läpimitta, lahoaste) sekä ympäröivän kasvillisuuden piirteet vaikuttavat tunnistukseen. Mäyrän ym. (n.d.) tutkimuksessa tarkasteltiin droonaineistojen tuomia lisähyötyjä lahopuun maastokartoituksessa sekä arvioitiin, kuinka suuri osuus lahopuusta on ylipäättään mahdollista havaita ilmakuvista. Lisäksi tutkimuksessa arvioitiin, miten opetusaineiston maantieteellinen kattavuus vaikuttaa tunnistuksen tarkkuuteen. Käytetyssä menetelmässä automaattiseen kuvantulkintaan kehitetyt konenäköalgoritmit opetettiin tunnistamaan maalahopuurunkoja sekä kuolleiden puiden latvuksia.

Epifyyttijäkälien lajirikkauden ja lajiyhteisöjen mallintaminen

Yhteensä 230 haapayksilön rungolta kartoitettiin epifyyttijäkälälajisto Evon tutkimusalueella kesällä 2018. Näistä haavoista 140 sijaitsi suojelalueiden ulkopuolella ja 70 suojelualueilla. Mukaan otettiin vain ne puut, joiden rungon läpimitta oli suurempi kuin 10 senttimetriä. Läpimitan lisäksi mitattiin myös puiden korkeus. Tutkimusaineistoa täydennettiin kesällä 2021, jolloin mitattiin rungon pH sekä kaarnan uurteiden syvyys ja paksuus yhteensä 140 aiemmin kartoitetusta haapayksilöstä.

Kaukokartoitusaineistoista laskettujen muuttujien soveltuvuutta haavan rungolla kasvavien epifyyttijäkälien lajirikkauden ja lajiyhteisöjen ennustamiseen tarkasteltiin lineaaristen regressiomallien ja hierarkkisten mallien (*hierarchical model of species communities*, HMSC) avulla (Palmroos ym. 2023). Kaukokartoitusmuuttujia verrattiin kentällä mitattuihin muuttujiin, jotta voitiin verrata molempien menetelmien tehokkuutta. Kenttämuuttujia olivat muun muassa kaarnan pH ja karkeus sekä rungon läpimitta. Lentolaserkeilausaineistosta laskettuja muuttujia olivat haavan pituus, keskimääräinen latvuston pituus, puiden lukumäärä ja latvuspeittävyys. Hyperspektiaaineistoista laskettiin muutajat puulajikoostumukselle. Kaikki muuttujat laskettiin 10 ja 30 metrin säteen ympyräkoeloille käyttäen mittaushoiteena ollutta haapaa keskipisteenä.

Tulokset


Haavan erottaminen muista puulajeista ja klorofyllipitoisuuden vaihtelu

Kaikki puulajit huomioiva kokonaisluokittelutarkkuus oli korkeimmillaan 84 prosenttia ja kappaarvo 0,78 (Viinikka ym. 2020). Haavan osalta kor-

kein luokittelutarkkuus 92 prosenttia (F1-arvo) saavutettiin tukivektorikone-luokittelijan avulla käyttäen yksittäisten kanavien heijastusominaisuuksia yhdessä kasvillisuusindeksien kanssa. Tärkeimmät aallonpituusalueet haavan erottamiseksi sijaitsivat punaisen ja lähi-infrapunan vaihtumisvyöhykkeen 724–727 nm (*red edge*) ja lähi-infrapunan 876 nm alueella, sekä aallonpituusalueilla 1520–1564 nm ja 1684–1706 nm. Monet kasvillisuusindeksit osoittautuivat tärkeiksi havupuiden ja lehtipuiden erottelussa, ja etenkin haavan erottamiseksi koivus-

ta, joka oli haastavaa lehtipuiden heijastusarvojen samankaltaisuuden takia.

Mäyrän ym. (2021) tutkimuksessa neljän pääpuulajin kokonaisluokittelutarkkuus oli korkeimmillaan 87 prosenttia, ja haavan osalta korkein F1-arvo oli 0,91. Parhaan mallin avulla tuotettiin koko tutkimusalueen kattava puulajikartta, jonka perusteella alueen puista noin 1,4 prosenttia oli haapoja (kuva 3). Yleisesti haavat esiintyivät hajanaisesti ympäri tutkimusaluetta, ja alueelta löydettiin vain muutamia isompia haavikkoja.



Kuva 3. Puulajikartta Evon tutkimusalueelta.
Figure 3. Tree species map covering the Evo study area.

Drooniaineistoihin pohjautuvassa tarkastelussa (Kuzmin ym. 2021) haapa pystyttiin erottamaan pääpuulajeista korkealla tarkkuudella pelkän RGB-aineiston avulla tukivektorikone-luokittelijaa käyttäen. Korkein kokonaisluokittelutarkkuus 83 prosenttia ja korkein haavan F1-arvo 86 prosenttia saavutettiin RGB- ja multispektriaineistojen yhteiskäytöllä.

Klorofyllipitoisuus vaihteli haapayksilöiden välillä kaikissa metsissä, eivätkä suojelualueet eronneet siinä suhteessa talousmetsistä (Keski-Saari ym. 2024). Puuston tiheys vaikutti haavanlehtien klorofyllipitoisuuteen talousmetsissä ja tienvarsilla. Vähiten klorofylliä oli tiheäkasvuisimmissa kasvupaikoissa, ja vastaavasti suurimmat klorofyllipitoisuudet olivat hyvin avoimella paikalla kasvavissa haavoissa. Haapayksilöiden välinen vaihtelu klorofyllipitoisuuksissa mahdollisti pitoisuuksien arvioimisen hyperspektriaineiston avulla. Paras

malli klorofyllipitoisuudelle oli indeksipohjainen RF-malli, jonka jäännösvirrehajonta (RMSE%) oli 11,7 prosenttia.

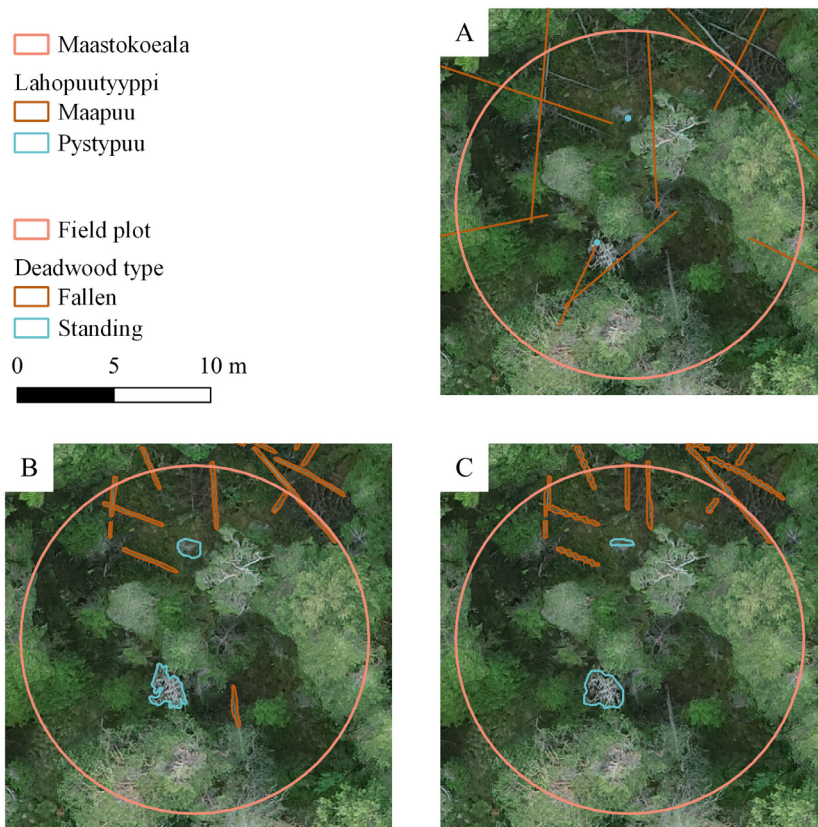
Lahopuun kartoittaminen ja siihen vaikuttavat tekijät

Optisiin drooniaineistoihin perustuvalla menetelmällä onnistuttiin paikantamaan valtaosa asiantuntijoiden ilmakuvien perusteella paikantamista maa- ja pystylahopuista. Näihin asiantuntijan manuaalisesti luomiin aineistoihin verrattuna menetelmät hieman yliarvioivat pystylahopuiden määrän, mutta aliarvioivat maalahopuiden määrän (Mäyrä ym. n.d.). On kuitenkin huomioitava, etteivät nämä vertailuaineistot kata kaikkea metsässä olevaa lahoppuuta, vaan pelkästään yläpuolelta havaittavissa olevan osan. Hiidenportin tutkimusalueen maastoaineistojen perusteella optisista drooniaineistoista ei pysty-

tä havaitsemaan kaikkia lahopuita, sillä korkeampi latvuspeitto hankaloittaa erityisesti maalahopuiden näkemistä. Vaikka maastossa koealoilta mitattujen ja asiantuntijoiden samoilta alueilta droonikuvien pohjalta paikantamien maalahopuiden kokonaismäärät olivatkin lähellä toisiaan, olivat asiantuntijoiden kuvilta paikantamat maalahopuut selkeästi lyhyempiä kuin maastossa mitatut (kuva 4).

Viivantunnistukseen pohjautuvalla menetelmällä tiheästä laserkeilausaineistosta pystyttiin havaitsemaan 30 prosenttia kaikista koealoilta mitatuista läpimitaltaan yli 10 senttimetriä olevista maalahopuista (Heinara ym. 2021). Maalahopuiden läpimitta ja pituus olivat merkittäviä tunnistukseen vaikuttavia tekijöitä ja esimerkiksi järeistä, läpimi-

taitaan yli 25 senttimetriä olevista maalahopuista kyettiin havaitsemaan 73 prosenttia. Menetelmän merkittävin haaste oli sen herkkyys virhetunnistuksille ja tutkimuksessa havaittiin, että tiheä alikasvos ja aluskasvillisuus johtivat yliarvioon maalahopuiden lukumäärästä. Jatkotutkimuksissa selvisi myös, että laserkeilausaineiston pistetiheyden kasvattaminen voi viivantunnistukseen perustuvilla menetelmillä nostaa virheellisten havaintojen määrää (Heinara ym. 2023). Maanpinnan muotojen ja kasvillisuuden kompleksisen rakenteen kuvaaminen erittäin tiheällä pistepilvellä lisää havaittavien yksityiskohtien määrää, mikä johtaa suureen määrään pistepilvestä tunnistettuja viivamaisia kohteita.



Kuva 4. Maalahopuiden ja pystylahopuiden tunnistaminen. A. kentämittaukset, B. käsin rajatut C. ennusteet.

Figure 4. Identification of downed dead trees and standing dead trees. A. field measurements, B. manually annotated, C. predictions.

Kaukokartoitusmuuttujat epifyyttijäkälien lajirikkauden ja lajiyhteisöjen ennustamisessa

Tulokset osoittivat, että kaukokartoituspohjaisilla mittareilla pystytään potentiaalisesti ennustamaan haavan epifyyttisiä jäkäläyhteisöjä yhtä hyvin tai jopa hiukan paremmin kuin maastossa mitatuilla muuttujilla. Hierarkkisen lajiyhteisömallin ennus-

tusarvot eri muuttujille jäivät yleisesti melko alhaisiksi, mutta paras ennustettavuus lajiyhteisölle saatiin kaukokartoituspohjaisilla muuttujilla. Parhaassa muuttujajyhdistelmässä olivat mukana latvuston keskikorkeus, puulajikoostumus ja puuston tiheys. Suurempi 30 metrin säteen koeala oli malleissa selkeästi ennustusarvoltaan parempi kuin pienempi 10 metrin säteen koeala, mikä osoittaa ympäristön

merkityksen lajijhteisöjen ennustamisessa. Tämä tulos omalta osaltaan tukee kaukokartoitus pohjaisen muuttujien käyttämistä lajirikkaiden kohteiden etsimisessä laajoilta alueilta.

Pohdinta

Avainlaji haavan tunnistaminen

Tuloksemme osoittavat, että korkearesoluutioisten kaukokartoitusaineistojen avulla on mahdollista tuottaa tarkkaa spatiaalista tietoa eri puulajien ja avainlaji haavan esiintymisestä. Aiemmissä tutkimuksissa haavan luokittelutarkkuus on vaihdellut paljon tutkimusalueen ominaisuuksien ja käytettyjen kaukokartoitusaineistojen mukaan (Kivinen ym. 2020). Puiden latvusten rajaaminen laserkeilausaineiston avulla, tutkimuksessa käytetyn hyperspektriaineiston laaja aallonpituusalue ja koneoppimistekniikoiden hyödyntäminen olivat todennäköisesti tärkeitä yksittäisiä osatekijöitä, jotka mahdollistivat hyvät tulokset puulajintunnistuksessa.

Puulajeja tunnistettaessa laadukas ja kattava aineisto sisältää sekä riittävän määrän havaintoja tarkasteltavista lajeista että havaintoja eri ympäristöoloissa kasvavista yksilöistä. Harvalukuisten puulajien sisällyttäminen tutkimuskohteeksi lisää yleisesti luokittelun virhemahdollisuutta (Roth ym. 2015). Kun tutkimuksen tavoitteena on harvalukuisten puulajien tarkka tunnistaminen, on mallien opetusaineisto sijoitettava alueille, joilla kyseisiä lajeja esiintyy (Korhonen ym. 2024). Ihanteellinen opetusaineisto olisi puuyksilölukumäärältään suuri ja kutakin lajia edustaisi yhtä monta puuyksilöä. Tämä tarkoittaa, että monille harvinaisille lajeille opetusaineistossa on oltava suojelualueita. Sen sijaan mallin testiaineistossa on oltava talousmetsiä, jotta mallin toimivuutta voidaan arvioida suojelualueen ulkopuolella. Esimerkiksi Mäyrän ym. (2021) tutkimuksessa opetusaineistossa oli 11 prosenttia haapaa, mutta koko 83 km² tutkimusalueella haapaa oli 1,4 prosenttia. Tämä vastanee todellista haavan esiintymistä Evon alueella.

Haapojen kartoittamisessa latvuksen näkyvyys ilmasta merkitsee käytännössä myös minimiläpimitan asettamista tarkasteltaville puuyksilöille. Suomessa suurikokoisten haapojen tunnistamista laserkeilausaineistoiden ja ilmakuvien avulla talousmetsissä on tutkinut esimerkiksi Toivonen ym. (2024). Tutkimuksessa havaittiin tarkasteltavien haapayksilöiden määrän ja läpimitan vaikutus luokittelutulokseen. Vanhat, järeät haavat ovat merkittäviä metsälajiston monimuotoisuuden turvaajia, ja siksi niiden esiintymisestä tarvitaan tietoa luonnon monimuotoisuuden nykytilan tarkasteluun (Maltamo ym. 2015). Haavan seuralaislajien elinvoimaisten populaatioiden

säilyminen edellyttää eri-ikäisten haapojen jatku-moa maisemassa (Kivinen ym. 2020), mutta nykyisillä menetelmillä nuorien haapojen tunnistaminen ilmasta käsin on vaikeaa.

Mallin hyvä yleistyskyky tarkoittaa, että malli pystyy tunnistamaan esimerkiksi puulajien spektritset eroavaisuudet ja erottamaan ne toisistaan myös tutkimusalueen ulkopuolisilla alueilla. Marconi ym. (2022) tutkivat, voiko yhdellä alueella lennetyn hyperspektriaineiston perusteella tunnistaa puulajeja toisella alueella. Tulokset osoittivat, että kaikilta tutkimusalueilta kerättyjen aineistojen perusteella tehty yhdistelmämallinnus toimi puulajintunnistuksessa hyvin, mutta yhden paikan perusteella tehdyt mallit toimivat heikosti toisella alueella. Yksi keskeinen tutkimusaihe tulevaisuudessa onkin paikallisella tasolla tehtyjen tutkimusten yleistettävyyks muille alueille.

Puulajien tunnistamista on tarkasteltu myös drooneilla kerätystä hyperspektriaineistosta. Tuominen ym. (2018) tutkivat 26 puulajin tunnistamista hyperspektriaineiston ja kolmiulotteisen fotogrammetrisen latvusmallin avulla. Haapa pystyttiin tunnistamaan suhteellisen korkealla tarkkuudella. Saarinen ym. (2018) tarkastelivat luonnon monimuotoisuutta kuvaavien indikaattorien kartoittamista hyperspektrikuvien ja fotogrammetristen pistepilvien avulla. Suurimmat virheet ennusteissa liittyivät tutkimusalueella harvalukuisena esiintyvien lehtipuiden, kuten haavan määrään ja tilavuuteen.

Lehtipuiden heijastusominaisuudet vaihtelevat kasvukauden eri aikoina ja aineiston kuvausajankohta voi vaikuttaa puulajien tunnistamiseen ja luokitustarkkuuteen. Hardenbol ym. (2021) tutkivat haapojen kartoittamista havupuuvaltaisessa metsässä kasvukauden eri aikoina droonien avulla kerätystä multispektriaineistosta. Korkein kaikkien puulajien luokittelutarkkuus oli 95 prosenttia ja haapapuiden luokittelutarkkuus oli 96–97 prosenttia termisen kasvukauden alussa toukokuussa. Hyvään tulokseen vaikuttivat lehtipuulajien välillä olevat fenologiset erot. Koivut olivat tuolloin puhjenneet lehteen, mutta haavat olivat vielä lehdettämiä.

Metsähaavan lehtien klorofyllipitoisuuksissa oli suurta vaihtelua yksilöiden välillä maisematasolla. Koska klorofyllipitoisuuden voidaan tulkita kerto-van kasvin kunnosta (Zarco-Tejada ym. 2002; Croft ym. 2017), tulos viittaa siihen, että hyväkuntoisia haapapuita esiintyi samassa suhteessa huonompikuntoisiin nähden suojelu- ja talousmetsissä. Tulos on merkillepantava, koska suojelumetsien puiden voisi ajatella olevan heikompia yhteyttäjiä, koska ne ovat iältään vanhempia. Puuston tiheys vaikutti klorofyllipitoisuuteen, mikä kertoo valon tärkeästä roolista klorofyllin kertymisessä. Tiheimät

ja harvimmat metsiköt sijaitsivat suojelualueiden ulkopuolella, harventamattomissa tiheiköissä ja hakkuualueilla. Suojelu- ja talousmetsien metsähaavat poikkesivat rakenteeltaan toisistaan: suojelumetsissä latvus oli lyhyempi kuin talousmetsissä ja tienvarsiapuilla. Suuri lajinsisäinen vaihtelu klorofyllipitoisuuksissa mahdollisti pitoisuuden arvioinnin maisematasolla heijastusspektristä hyvällä tarkkuudella.

Maa- ja pystylahopuun kartoittaminen

Tulokset osoittivat, että korkeatiheyskisen laserkeilausaineiston ja RGB-kuvien avulla voidaan kartoittaa kohtuullisella tarkkuudella maalahopuun esiintymistä. Maalahopuun on kaukokartoitusmenetelmien kannalta haastava kohde, sillä suuri osa siitä sijaitsee elävän latvuston alla. Tästä syystä maalahopuun kartoittamiseen tähtäviä tutkimuksia on verrattain vähän. Tutkimuksissa on tyypillisesti käytetty hyvin tiheitä lento- tai maastolaserkeilausaineistoja (Lindberg ym. 2013; Yrttimaa ym. 2019) ja hyödynnetty myös heijastuvan laserpulssin aaltomuotoa (Mücke ym. 2013), mikä mahdollistaa maanpinnan lähellä olevien kohteiden yksityiskohtaisen mittaamisen ja luokittelun.

Viime vuosina lahopuun kartoituksen tutkimus on keskittynyt pitkälti kuolleiden, mutta edelleen pystyssä olevien puiden tunnistamiseen. Jutras-Perreault ym. (2023) luokittelivat kuolleita puita lentolaserkeilausaineiston perusteella tehdyn yksinpuintulkinnan sekä hyperspektri- ja satelliittiaineistoista määritetyn NDVI-kasvillisuusindeksin avulla. Menetelmällä saatiin lupaavia tuloksia sekä lentokoneesta että satelliiteista kerättyjen optisten aineistojen avulla. Toisessa tutkimuksessa (Briechele ym. 2021) käytettiin tiheään lentolaserkeilaukseen perustuvaa yksinpuintulkintaa ja multispektrikuvia puulajien ja pystyyn kuolleiden puiden luokittelussa. Tutkimuksessa esitelty konvoluutioneuroverkkoja hyödyntävä menetelmä ylsi erinomaisiin tuloksiin sekä elävien että kuolleiden puiden luokittelussa.

Etenkin maalahopuun kartoituksessa voidaan käyttää lähinnä lentokoneiden ja droonien avulla kerättyä aineistoa, koska korkearesoluutisimmatkin kaupalliset satelliittikuva-aineistot ovat spatiaaliselta erotuskyvyltään liian epätarkkoja maassa, osittain latvuston alla makaavien kohteiden erottamiseen. Erittäin korkealaatuisten aineistojen lisäksi aiemmille tutkimuksille on ollut tyypillistä tutkimuskohteeseen sovitettua menetelmää. Siksi menetelmien yleistäminen kohdealueiden ulkopuolelle on usein haastavaa joko sopivien laserkeilausaineistojen puuttuessa tai koska menetelmät on sovitettava kartoitettaviin kohteisiin erillisten opetusaineistojen avulla.

Sekä maa- että pystylahopuiden tunnistaminen nojaa kohteiden suoraan tunnistamiseen, mikä on hyvä huomioida tuloksia tulkitessa. Etenkin pystylahopuiden osalta tutkimukset antavat usein ylioptimistisia tuloksia, sillä niissä keskitytään menetelmän sisäiseen tarkkuuteen. Tällöin ne puut, joita ei ole kaukokartoitusaineistoista havaittu eivät myöskään vaikuta luokittelutulokseen. Siten menetelmän sisäinen tarkkuus ei vastaa sen kykyä kuvata tarkasteltua ilmiötä laajemmin. Esimerkkinä tästä ovat kuolleet pötkelöt, jotka latvuksettomina ovat erittäin hankalia havaita elävän latvuksen yläpuolelta lentokoneita tai satelliitteja hyödyntävillä kaukokartoitusmenetelmillä. Tulevaisuuden tavoitteenamme onkin, että droonilennoilla tuotettua lahopuiden sijaintitietoa voidaan käyttää seuraavassa vaiheessa validointiaineistona esimerkiksi laajemmalle alueelle tehtävissä satelliittiaineistoihin perustuvissa pystylahopuun kartoituksissa.

Lajirikkauden ja lajiyhteisöjen ennustaminen kaukokartoitusaineistoista

Epfifyytjäkälien lajirikkauden ja lajiyhteisöjen ennustamiseen liittyvät tulokset tukevat näkemystä, että erilaisia kaukokartoitusaineistoja voidaan hyödyntää jatkossa boreaalisten metsien monimuotoisuuskohteiden löytämisessä. Tieto ekosysteemien kolmiulotteisesta rakenteesta on oleellista ekosysteemien prosessien ja lajiston monimuotoisuuden ymmärtämisessä ja kartoittamisessa (LaRue ym. 2023). Laserkeilausaineistosta johdettuja muuttujia, kuten latvuston korkeutta ja peittävyyttä sekä latvuston ja pohjakerroksen rakennetta on käytetty laajasti eri lajiryhmien ekologisessa tutkimuksessa (Melin ym. 2016; Acebes ym. 2021; Toivonen ym. 2023). Tutkimusta löytyy eniten lintujen ja ekosysteemin rakennetta kuvaavien metriikoiden yhteydestä (Melin ym. 2018; Mononen ym. 2018; Acebes ym. 2021). Hakkenbergin ym. (2017) tulokset osoittivat, että korkearesoluutioisesta lentolaserkeilausaineistosta laskettujen metsän rakennetta kuvaavien muuttujien ja hyperspektriaineistosta laskettujen muuttujien avulla voidaan ennustaa latvuserroksen koostumuksen lisäksi myös latvuston alapuolisten kerrosten kasvillisuuden koostumusta.

Klein ym. (2020) tarkastelivat kansallisen lentolaserkeilausaineiston avulla jäkälien ja lintujen lajirikkauden suhdetta metsän rakenteeseen ja havaitsivat, että kasvillisuuden tiheydellä on erilainen vaikutus jäkälien ja lintujen lajirikkauteen. Tällaisella tiedolla on tärkeä rooli muun muassa monimuotoisuutta tukevien metsänhoitoon liittyvien toimenpiteiden suunnittelussa. On kuitenkin huomattava, että vaikka kaukokartoituksen avulla voidaan arvioida potentiaalisia kohteita monimuotoisuudel-

le ja jopa ennustaa lajiyhteisöjä, tarkka tieto lajistosta vaatii maastokäyntiä. Kaukokartoitusaineistosta laskettuja muuttujia voidaan hyödyntää myös esimerkiksi lajistoon liittyvien maastoinventointien kohdentamisessa.

Johtopäätökset

Eri kaukokartoitusmenetelmien käyttöön liittyy erilaisia etuja ja haasteita, ja monimuotoisuuteen liittyvien piirteiden kartoitukseen valitut menetelmät määräytyvät tavoitteiden, maantieteellisen laajuuden ja käytettävissä olevien resurssien mukaan. Korkean spatiaalisen ja spektrisen erotuskyvyn omaavien aineistojen avulla voidaan erottaa ekologisesti merkittäviä piirteitä, mutta tarkasteltavan piirteen koko, sijoittuminen suhteessa latvuserokseen ja harvalukuisuus asettavat rajoituksia piirteen tunnistamiselle.

Korkearesoluutioiset lentokoneesta tai droonista kuvatut aineistot kattavat useimmiten rajallisen maantieteellisen alueen, mikä estää tällä hetkellä kehittyneimpien mallinnusmenetelmien yleistämisen yksittäisten tutkimusalueiden ulkopuolelle. Etenkin lentokoneesta kerättävä hyperspektriaineisto on kallista, joten se ei tällä hetkellä sovelu operatiiviseksi, kansallisen tason aineistonkeruumenetelmäksi. Myöskään korkearesoluutioisia laserkeilausaineistoja ei ole tällä hetkellä saatavana valtakunnallisella tasolla. Tulevaisuudessa hyperspektrikameratekniikoiden edelleen kehittyessä, satelliiteista tehtävä hyperspektrikuvaus voisi korvata lentokuvauksen. Samanaikaisesti koneoppimismenetelmät ja eri tahojen, kuten Tieteen tietotekniikan keskus CSC:n tarjoamat kehittyneet laskentapalvelut mahdollistavat isojen datamassojen tehokkaan käsittelyn ja analysoinnin. Hyperspektriaineistojen käsittely on työläämpää kuin multispektriaineistojen ja sopivimman aineiston valinta vaatii tapauskohtaisesti kustannusten ja hyötyjen arviointia (esim. Upadhyay & Kumar 2018). Hyperspektriaineistoilla tehdyn tutkimuksen pohjalta saadaan uutta tietoa, jonka avulla voidaan kehittää myös uusia edullisia multispektrensensoreita operatiiviseen käyttöön.

Kaukokartoitusmenetelmien kehittyminen vähentää laajojen maastotöiden tarvetta. Esimerkiksi droonien avulla kerättyjä aineistoja voidaan hyödyntää maisema- ja valtakunnallisen tason analyyseissä käytettävien kaukokartoitusaineistojen tukena ja myös osittain korvata maastossa kerättyjä opetusaineistoja (Fassnacht ym. 2024). Maastotöitä ei voida kuitenkaan kokonaan korvata kaukokartoituksella, koska laadukkaita maastoaineistoja tarvitaan edelleen muun muassa opetus- ja vertailuaineistoksi malleihin. Myös eri eliölajien esiintymisen mal-

laintaminen kaukokartoitusaineistoista laskettujen muuttujien suhteen vaatii lajiaineistojen keräämistä maastossa (Senf 2020; Reddy ym. 2024).

Metsäekosysteemeissä tapahtuvat muutokset ja metsävarojen käyttöön liittyvät paineet vaativat tietoa monimuotoisuutta ilmentävien piirteiden sekä tämänhetkisestä tilasta että niiden muutoksista (Alam ym. 2023). Tämä edellyttää seuranta- eli samalla alueella samalla menetelmällä kohteeseen kajoamatta toistettavissa olevaa tutkimusta. Yksittäisissä tutkimushankkeissa syntyy uutta ymmärrystä ja tietoa erilaisten kartoitusmenetelmien mahdollisuuksista, mutta laajempien alueiden kartoittaminen ja seuranta vaatii pidempiä aikaisia resursseja ja yhteistyötä eri organisaatioiden välillä. Hyvänä esimerkkinä yhteistyöstä on niin kutsuttu KALLIO-yhteistyöelin, joka koostuu useammasta organisaatiosta, jotka ohjaavat ja rahoittavat kansallisia laserkeilaus- ja ilmakuvausohjelmia. Tämän kaltaisen yhteistyön tavoitteena on mahdollistaa valtakunnallisten aineistojen saannin jatkuvuus, joka on ehtona esimerkiksi seuranta-aineistojen ja muutosanalyysien tuottamiselle.

Kiitokset

IBC-Carbon-hanketta (Integrated Biodiversity Conservation and Carbon Sequestration in the Changing Environment, projektnumero 312559) on rahoittanut Suomen Akatemian yhteisessä toimiva Strategisen tutkimuksen neuvosto. Kiitämme myös yhteistyöstä Beetles-LIFE-hanketta. Hanke on saanut rahoitusta Euroopan unionin LIFE-ohjelmasta. Aineiston sisältö heijastelee sen tekijöiden näkemyksiä, eikä Euroopan komissio tai CINEA ole vastuussa aineiston sisältämien tietojen käytöstä. Samoin kiitämme Suomen Akatemian rahoittamaa C-NEUT-hanketta (projektnumero 347862) ja Suomen ekosysteemiobservatorio FEO-hanketta. Kiitokset Aleksii Ritakalliolle, Max Strandénille, Tytti Jussilalle, Niina Kiljuselle, Aleksandra Rikille, Franziska Wolffille, Elisa Kropsulle ja Osmo Suomiselle avusta maastomittauksissa ja Tieteen tietotekniikan keskukselle CSC:lle laskentaresursseista.

KIRJALLISUUS

- Acebes, P., Lillo, P. & Jaime-González, C. (2021) Disentangling LiDAR contribution in modelling species-habitat structure relationships in terrestrial ecosystems worldwide. A systematic review and future directions. *Remote Sensing* 13(17) 3447. <https://doi.org/10.3390/rs13173447>
- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R. & Sousa, J. J. (2017) Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote Sensing* 9(11) 1110. <https://doi.org/10.3390/rs9111110>

- Adnan S. (2020) Improvements in forest structural type assessment using airborne laser scanning. *Dissertationes Forestales* 306. <https://doi.org/10.14214/df.306>
- Alam, S. A., Kivinen, S., Kujala, H., Tanhuanpää, T. & Forsius, M. (2023) Integrating carbon sequestration and biodiversity impacts in forested ecosystems: Concepts, cases, and policies. *Ambio* 52(11) 1687–1696. <https://doi.org/10.1007/s13280-023-01931-3>
- Audebert, N., Le Saux, B. & Lefèvre, S. (2019) Deep learning for classification of hyperspectral data: A comparative review. *IEEE Geoscience and Remote Sensing Magazine* 7(2) 159–173. <https://doi.org/10.1109/MGRS.2019.2912563>
- Beland, M., Parker, G., Sparrow, B., Harding, D., Chasmer, L., Phinn, S., Antonarakis, A. & Strahler, A. (2019) On promoting the use of lidar systems in forest ecosystem research. *Forest Ecology and Management* 450, 117484. <https://doi.org/10.1016/j.foreco.2019.11748>
- Berner, L. T. & Goetz, S. J. (2022) Satellite observations document trends consistent with a boreal forest biome shift. *Global Change Biology* 28(10) 3275–3292. <https://doi.org/10.1111/gcb.16121>
- Briechele, S., Krzystek, P. & Vosselman, G. (2021) SilviNet – A dual-CNN approach for combined classification of tree species and standing dead trees from remote sensing data. *International Journal of Applied Earth Observation and Geoinformation* 98, 102292. <https://doi.org/10.1016/j.jag.2020.102292>
- Camarretta, N., Harrison, P. A., Bailey, T., Potts, B., Lucieer, A., Davidson, N. & Hunt, M. (2020) Monitoring forest structure to guide adaptive management of forest restoration: a review of remote sensing approaches. *New Forests* 51, 573–596. <https://doi.org/10.1007/s11056-019-09754-5>
- Cavender-Bares, J., Schneider, F. D., Santos, M. J., Armstrong, A., Carnaval, A., Dahlin, K. M., Fatoyinbo, L., Hurr, G.C., Schimel, D., Townsend, P.A., Ustin, S. L., Wang, Z. & Wilson, A. M. (2022) Integrating remote sensing with ecology and evolution to advance biodiversity conservation. *Nature Ecology & Evolution* 6(5) 506–519. <https://doi.org/10.1038/s41559-022-01702-5>
- Ćosović, M., Bugalho, M. N., Thom, D. & Borges, J. G. (2020) Stand structural characteristics are the most practical biodiversity indicators for forest management planning in Europe. *Forests* 11(3) 343. <https://doi.org/10.3390/f11030343>
- Dalponte, M., Ørka, H. O., Gobakken, T., Gianelle, D. & Næsset, E. (2012) Tree species classification in boreal forests with hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing* 51(5) 2632–2645. <https://doi.org/10.1109/TGRS.2012.2216272>
- Deepak, M., Keski-Saari, S., Fauch, L., Granlund, L., Oksanen, E. & Keinänen, M. (2020) Spectral reflectance in silver birch genotypes from three provenances in Finland. *Remote Sensing* 12(17) 2677. <https://doi.org/10.3390/rs12172677>
- Degerickx, J., Roberts, D. A., McFadden, J. P., Hermy, M. & Somers, B. (2018) Urban tree health assessment using airborne hyperspectral and LiDAR imagery. *International Journal of Applied Earth Observation and Geoinformation* 73, 26–38. <https://doi.org/10.1016/j.jag.2018.05.021>
- Esseen, P. A., Ehnström, B., Ericson, L. & Sjöberg, K. (1997) Boreal forests. *Ecological Bulletins* 46, 16–47.
- European Commission (2024) Proposal for a Nature Restoration Law. https://environment.ec.europa.eu/publications/nature-restoration-law_en 26.2.2024.
- Fassnacht, F. E., White, J. C., Wulder, M. A., & Næsset, E. (2024) Remote sensing in forestry: current challenges, considerations and directions. *Forestry: An International Journal of Forest Research* 97(1) 11–37. <https://doi.org/10.1093/forestry/cpad024>
- Forsius, M., Kujala, H., Minunno, F., Holmberg, M., Leikola, N., Mikkonen, N., Autio, A., Paunu, V-V, Tanhuanpää, T., Hurskainen, P., Mäyrä, J., Kivinen, S., Keski-Saari, S., Kosenius, A-K, Kuusela, S., Virkkala, R., Viinikka, A., Vihervaara, P., Akujärvi, A., Bäck, J. & Heikkinen, R. K. (2021) Developing a spatially explicit modelling and evaluation framework for integrated carbon sequestration and biodiversity conservation: Application in southern Finland. *Science of the Total Environment* 775, 145847. <https://doi.org/10.1016/j.scitotenv.2021.145847>
- Gauthier, S., Bernier, P., Kuuluvainen, T., Shvidenko, A. Z. & Schepaschenko, D. G. (2015) Boreal forest health and global change. *Science* 349(6250) 819–822. <https://doi.org/10.1126/science.aaa9092>
- Gini, R., Sona, G., Ronchetti, G., Passoni, D. & Pinto, L. (2018) Improving tree species classification using UAS multispectral images and texture measures. *ISPRS International Journal of Geo-Information* 7(8) 315. <https://doi.org/10.3390/ijgi7080315>
- Hakkenberg, C. R., Peet, R. K., Urban, D. L. & Song, C. (2018) Modeling plant composition as community continua in a forest landscape with LiDAR and hyperspectral remote sensing. *Ecological Applications* 28(1) 177–190. <https://doi.org/10.1002/eap.1638>
- Hardenbol, A. A., Kuzmin, A., Korhonen, L., Korpelainen, P., Kumpula, T., Maltamo, M. & Kouki, J. (2021) Detection of aspen in conifer-dominated boreal forests with seasonal multispectral drone image point clouds. *Silva Fennica* 55(4) 10515. <https://doi.org/10.14214/sf.10515>
- Heinero, E., Tanhuanpää, T., Yrttimaa, T., Holopainen, M. & Vastaranta, M. (2021) Airborne laser scanning reveals large tree trunks on forest floor. *Forest Ecology and Management* 491, 119225. <https://doi.org/10.1016/j.foreco.2021.119225>

- Heinano, E., Tanhuanpää, T., Vastaranta, M., Yrttimaa, T., Kukko, A., Hakala, T., Mattsson, T. & Holopainen, M. (2023) Evaluating factors impacting fallen tree detection from airborne laser scanning point clouds. *Remote Sensing* 15(2), 382. <https://doi.org/10.3390/rs15020382>
- Hekkala, A. M., Jönsson, M., Kärvelo, S., Strengbom, J. & Sjögren, J. (2023) Habitat heterogeneity is a good predictor of boreal forest biodiversity. *Ecological Indicators* 148, 110069. <https://doi.org/10.1016/j.ecolind.2023.110069>
- Hu, T., Sun, X., Su, Y., Guan, H., Sun, Q., Kelly, M. & Guo, Q. (2020) Development and performance evaluation of a very low-cost UAV-LiDAR system for forestry applications. *Remote Sensing* 13(1) 77. <https://doi.org/10.3390/rs13010077>
- Im, J. & Jensen, J. R. (2008) Hyperspectral remote sensing of vegetation. *Geography Compass* 2(6) 1943–1961. <https://doi.org/10.1111/j.1749-8198.2008.00182.x>
- Jensen, J. R. (2000) *Remote sensing of the environment: an earth resource perspective*. Prentice-Hall, New Jersey.
- Jonsson, B. G., Krus, N. & Ranius, T. (2005) Ecology of species living on dead wood – lessons for dead wood management. *Silva Fennica* 39(2) 289–309.
- Jutras-Perreault, M. C., Gobakken, T., Næsset, E. & Ørka, H. O. (2023) Comparison of different remotely sensed data sources for detection of presence of standing dead trees using a tree-based approach. *Remote Sensing* 15(9) 2223. <https://doi.org/10.3390/rs15092223>
- Juutinen, A., Mönkkönen, M. & Sippola, A. L. (2006) Cost-efficiency of decaying wood as a surrogate for overall species richness in boreal forests. *Conservation Biology* 20(1) 74–84. <https://doi.org/10.1111/j.1523-1739.2005.00306>
- Keski-Saari, S., Keinänen, M., Mäyrä, J., Viinikka, A., Tanhuanpää, T., Poikolainen, L., Kivinen, S., Vihervaara, P. & Kumpula, T. (2024) Foliar chlorophyll and carotenoid contents of European aspen assessed by airborne imaging spectroscopy across landscape. Pre-print 24.7.2024. <https://dx.doi.org/10.2139/ssrn.4904115>
- Kivinen, S., Koivisto, E., Keski-Saari, S., Poikolainen, L., Tanhuanpää, T., Kuzmin, A., Viinikka, A., Heikkinen, R. K., Pykälä, J., Virkkala, R., Vihervaara, P. & Kumpula, T. (2020) A keystone species, European aspen (*Populus tremula* L.), in boreal forests: Ecological role, knowledge needs and mapping using remote sensing. *Forest Ecology and Management* 462, 118008. <https://doi.org/10.1016/j.foreco.2020.118008>
- Klein, J., Thor, G., Low, M., Sjögren, J., Lindberg, E. & Eggers, S. (2020) What is good for birds is not always good for lichens: Interactions between forest structure and species richness in managed boreal forests. *Forest Ecology and Management* 473, 118327. <https://doi.org/10.1016/j.foreco.2020.118327>
- Korhonen, L., Kärhä, K., Maltamo, M., Malinen, J., Hyypä, J., Kaartinen, H., Toivonen, J., Packalen, P. & Koivula, M. (2024) Kaukokartoitus ja metsäkoneiden sensorit metsien monimuotoisuusindikaattorien seurannassa. *Metsätieteen aikakauskirja* 23010. <https://doi.org/10.14214/ma.23010>
- Korpela, I., Ørka, H. O., Maltamo, M., Tokola, T. & Hyypä, J. (2010) Tree species classification using airborne LiDAR—effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fennica* 44, 319–339.
- Kouki, J., Arnold, K. & Martikainen, P. (2004) Long-term persistence of aspen – a key host for many threatened species – is endangered in old-growth conservation areas in Finland. *Journal for Nature Conservation* 12(1) 41–52. <https://doi.org/10.1016/j.jnc.2003.08.002>
- Kuuluvainen, T. (2002) Natural variability of forests as a reference for restoring and managing biological diversity in boreal Fennoscandia. *Silva Fennica* 36(1) 97–125.
- Kuuluvainen, T., Wallenius, T. & Pennanen, J. (2004) Metsien luontainen rakenne, dynamiikka ja monimuotoisuus. Teoksessa Kuuluvainen, T., Saaristo, L., Keto-Tokoi, P., Kostamo, J., Kuuluvainen, J., Kuusinen, M., Ollikainen, M. & Salpakivi-Salomaa, P. (toim.) *Metsän kätköissä: Suomen metsäluonnon monimuotoisuus*, 48–75. Edita.
- Kuzmin, A., Korhonen, L., Kivinen, S., Hurskainen, P., Korpelainen, P., Tanhuanpää, T., Maltamo, M., Vihervaara, P. & Kumpula, T. (2021) Detection of European aspen (*Populus tremula* L.) based on an unmanned aerial vehicle approach in boreal forests. *Remote Sensing* 13(9) 1723. <https://doi.org/10.3390/rs13091723>
- Larsson, S. & Danell, K. (2001) Science and the management of boreal forest biodiversity. *Scandinavian Journal of Forest Research* 16(S3) 5–9.
- LaRue, E. A., Fahey, R. T., Alvshere, B. C., Atkins, J. W., Bhatt, P., Buma, B., ... & Fei, S. (2023) A theoretical framework for the ecological role of three-dimensional structural diversity. *Frontiers in Ecology and the Environment* 21(1) 4–13. <https://doi.org/10.1002/fee.2587>
- Lary, D. J., Alavi, A. H., Gandomi, A. H. & Walker, A. L. (2016) Machine learning in geosciences and remote sensing. *Geoscience Frontiers* 7(1) 3–10. <https://doi.org/10.1016/j.gsf.2015.07.003>
- Lassauce, A., Paillet, Y., Jactel, H. & Bouget, C. (2011) Deadwood as a surrogate for forest biodiversity: meta-analysis of correlations between deadwood volume and species richness of saproxylic organisms. *Ecological Indicators* 11(5) 1027–1039. <https://doi.org/10.1016/j.ecolind.2011.02.004>

- Lausch, A., Bannehr, L., Beckmann, M., Boehm, C., Feilhauer, H., Hacker, J. M., ... & Cord, A. F. (2016) Linking Earth Observation and taxonomic, structural and functional biodiversity: Local to ecosystem perspectives. *Ecological Indicators* 70, 317–339. <https://doi.org/10.1016/j.ecolind.2016.06.022>
- Lindberg, E., Hollaus, M., Mücke, W., Fransson, J. E. & Pfeifer, N. (2013) Detection of lying tree stems from airborne laser scanning data using a line template matching algorithm. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 2, 169–174.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. & Johnson, B. A. (2019) Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing* 152, 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Madritch, M. D., Kingdon, C. C., Singh, A., Mock, K. E., Lindroth, R. L. & Townsend, P. A. (2014) Imaging spectroscopy links aspen genotype with below-ground processes at landscape scales. *Philosophical Transactions of the Royal Society B: Biological Sciences* 369(1643) 20130194. <https://doi.org/10.1098/rstb.2013.0194>
- Maltamo, M., Pesonen, A., Korhonen, L., Kouki, J., Vehmas, M. & Eerikäinen, K. (2015) Inventory of aspen trees in spruce dominated stands in conservation area. *Forest Ecosystems* 2, 1–12. <https://doi.org/10.1186/s40663-015-0037-4>
- Marconi, S., Weinstein, B. G., Zou, S., Bohlman, S. A., Zare, A., Singh, A., ... & White, E. P. (2022) Continental-scale hyperspectral tree species classification in the United States National Ecological Observatory Network. *Remote Sensing of Environment* 282, 113264. <https://doi.org/10.1016/j.rse.2022.113264>
- Melin, M., Matala, J., Mehtätalo, L., Pusenius, J. & Packalen, P. (2016) Ecological dimensions of airborne laser scanning—Analyzing the role of forest structure in moose habitat use within a year. *Remote Sensing of Environment* 173, 238–247.
- Melin, M., Hinsley, S. A., Broughton, R. K., Bellamy, P. & Hill, R. A. (2018) Living on the edge: utilising lidar data to assess the importance of vegetation structure for avian diversity in fragmented woodlands and their edges. *Landscape Ecology* 33, 895–910.
- Mononen, L., Auvinen, A. P., Packalen, P., Virkkala, R., Valbuena, R., Bohlin, I., ... & Vihervaara, P. (2018) Usability of citizen science observations together with airborne laser scanning data in determining the habitat preferences of forest birds. *Forest Ecology and Management* 430, 498–508.
- Mücke, W., Deák, B., Schroiff, A., Hollaus, M. & Pfeifer, N. (2013) Detection of fallen trees in forested areas using small footprint airborne laser scanning data. *Canadian Journal of Remote Sensing* 39(sup1) S32–S40. <https://doi.org/10.5589/m13-013>
- Mäyrä, J., Keski-Saari, S., Kivinen, S., Tanhuanpää, T., Hurskainen, P., Kullberg, P., Poikolainen, L., Viinikka, A., Tuominen, S., Kumpula, T. & Vihervaara, P. (2021) Tree species classification from airborne hyperspectral and LiDAR data using 3D convolutional neural networks. *Remote Sensing of Environment* 256, 112322. <https://doi.org/10.1016/j.rse.2021.112322>
- Mäyrä, J., Tanhuanpää, T., Heinaro, E., Kuzmin, A., Kumpula, T. & Vihervaara, P. (n.d.) UAVs and deep learning can enhance the mapping of deadwood in boreal forests. *Julkaisematon käsikirjoitus*.
- Määttänen, A. M., Virkkala, R., Leikola, N. & Heikkinen, R. K. (2022) Increasing loss of mature boreal forests around protected areas with red-listed forest species. *Ecological Processes* 11(1) 17. <https://doi.org/10.1186/s13717-022-00361-5>
- Mönkkönen, M. (2004) Suomen metsäluonto—osa globaalia monimuotoisuutta. Teoksessa Kuuluvainen, T., Saaristo, L., Keto-Tokoi, P., Kostamo, J., Kuuluvainen, J., Kuusinen, M., Ollikainen, M. & Salpakivi-Salomaa, P. (toim.) *Metsän kätköissä. Suomen metsäluonnon monimuotoisuus*, 19–47. Edita.
- Nevalainen, O., Honkavaara, E., Tuominen, S., Viljanen, N., Hakala, T., Yu, X., Hyypä, J., Saari, H., Pölönen, I., Imai, N. N. & Tommaselli, A. M. (2017) Individual tree detection and classification with UAV-based photogrammetric point clouds and hyperspectral imaging. *Remote sensing* 9(3) 185. <https://doi.org/10.3390/rs9030185>
- Oettel, J. & Lapin, K. (2021) Linking forest management and biodiversity indicators to strengthen sustainable forest management in Europe. *Ecological Indicators* 122, 107275. <https://doi.org/10.1016/j.ecolind.2020.107275>
- Packalén, P. & Maltamo, M. (2007) The k-MSN method for the prediction of species-specific stand attributes using airborne laser scanning and aerial photographs. *Remote Sensing of Environment* 109(3) 328–341. <https://doi.org/10.1016/j.rse.2007.01.005>
- Palmroos, I., Norros, V., Keski-Saari, S., Mäyrä, J., Tanhuanpää, T., Kivinen, S., Pykälä, J., Kullberg, P., Kumpula, T. & Vihervaara, P. (2023) Remote sensing in mapping biodiversity – A case study of epiphytic lichen communities. *Forest Ecology and Management* 538, 120993. <https://doi.org/10.1016/j.foreco.2023.120993>
- Piironen, R., Heiskanen, J., Maeda, E., Viinikka, A. & Pellikka, P. (2017) Classification of tree species in a diverse African agroforestry landscape using imaging spectroscopy and laser scanning. *Remote Sensing* 9(9) 875. <https://doi.org/10.3390/rs9090875>
- Reddy, C. S. (2021) Remote sensing of biodiversity: what to measure and monitor from space to species? *Biodiversity and Conservation* 30(10) 2617–2631. <https://doi.org/10.1007/s10531-021-02216-5>

- Reddy, C. S., Satish, K. V., Saranya, K. R. L., Sri Surya, N. N., Neha, P. A. & Rajashekar, G. (2024) Harnessing essential biodiversity variables and remote sensing of earth observations-synthesizing biodiversity insights. *Spatial Information Research* 32(3) 265–276. <https://doi.org/10.1007/s41324-023-00558-6>
- Roth, K. L., Roberts, D. A., Dennison, P. E., Alonzo, M., Peterson, S. H. & Beland, M. (2015) Differentiating plant species within and across diverse ecosystems with imaging spectroscopy. *Remote Sensing of Environment* 167, 135–151. <https://doi.org/10.1016/j.rse.2015.05.007>
- Saarinen, N., Vastaranta, M., Näsi, R., Rosnell, T., Hakala, T., Honkavaara, E., Wulder, M.A., Luoma, V., Tommaselli, A. M. G., Imai, N. N., Ribeiro, E. A. V., Guimarães, R. B., Holopainen, M. & Hyypä, J. (2018) Assessing biodiversity in boreal forests with UAV-based photogrammetric point clouds and hyperspectral imaging. *Remote Sensing* 10(2) 338. <https://doi.org/10.3390/rs10020338>
- Schiefer, F., Kattenborn, T., Frick, A., Frey, J., Schall, P., Koch, B. & Schmittlein, S. (2020) Mapping forest tree species in high resolution UAV-based RGB-imagery by means of convolutional neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing* 170, 205–215.
- Senf, C. (2020) Seeing the system from above: The use and potential of remote sensing for studying ecosystem dynamics. *Ecosystems* 25, 1719–1737. <https://doi.org/10.1007/s10021-022-00777-2>
- Siitonen, J. (2001) Forest management, coarse woody debris and saproxylic organisms: Fennoscandian boreal forests as an example. *Ecological Bulletins* 49, 11–41. <http://www.jstor.org/stable/20113262>
- Skidmore, A. K., Coops, N. C., Neinavaz, E., Ali, A., Schaepman, M. E., Paganini, M., ... & Wingate, V. (2021) Priority list of biodiversity metrics to observe from space. *Nature Ecology & Evolution* 5(7) 896–906. <https://doi.org/10.1038/s41559-021-01451-x>
- Sothe, C., De Almeida, C. M., Schimalski, M. B., La Rosa, L. E. C., Castro, J. D. B., Feitosa, R. Q., Dalponte, M., Lima, C. L., Liesenberg, V., Miyoshi, G. T. & Tommaselli, A. M. G. (2020) Comparative performance of convolutional neural network, weighted and conventional support vector machine and random forest for classifying tree species using hyperspectral and photogrammetric data. *GIScience & Remote Sensing* 57(3) 369–394. <https://doi.org/10.1080/15481603.2020.1712102>
- Suomen Metsäkeskus (2021) Puustotulkintakoealojen maastotyöohje.
- Syrjänen, K., Korhonen, K. T., Punttila, P. & Siitonen, J. (2024) *Luonnontilaiset ja vanhat metsät Suomessa. Euroopan komission ohjeet ja kansallinen tarkastelu. Suomen ympäristökeskuksen raportteja 2/2024.*
- Tang, L. & Shao, G. (2015) Drone remote sensing for forestry research and practices. *Journal of Forestry Research* 26, 791–797. <https://doi.org/10.1007/s11676-015-0088-y>
- Tanhuanpää, T., Mikkonen, N., Kujala, H., Heinaro, E., Mäyrä, J. & Kumpula, T. (2023) Input data resolution affects the conservation prioritization outcome of spatially sparse biodiversity features. *Ambio* 52, 1793–1803. <https://doi.org/10.1007/s13280-023-01885-6>
- Thiel, C., Mueller, M. M., Epple, L., Thau, C., Hese, S., Voltersen, M. & Henkel, A. (2020) UAS imagery-based mapping of coarse wood debris in a natural deciduous forest in central Germany (Hainich National Park). *Remote Sensing* 12(20) 3293. <https://doi.org/10.3390/rs12203293>
- Toivonen, J., Kangas, A., Maltamo, M., Kukkonen, M. & Packalen, P. (2023) Assessing biodiversity using forest structure indicators based on airborne laser scanning data. *Forest Ecology and Management* 546, 121376. <https://doi.org/10.1016/j.foreco.2023.121376>
- Toivonen, J., Kangas, A., Maltamo, M., Kukkonen, M. & Packalen, P. (2024) Mapping large European aspen (*Populus tremula* L.) in Finland using airborne lidar and image data. *Canadian Journal of Forest Research* 54, 762–773. <https://doi.org/10.1139/cjfr-2023-0271>
- Tuominen, S., Näsi, R., Honkavaara, E., Balazs, A., Hakala, T., Viljanen, N., Pölonen, I., Saari, H. & Ojanen, H. (2018) Assessment of classifiers and remote sensing features of hyperspectral imagery and stereo-photogrammetric point clouds for recognition of tree species in a forest area of high species diversity. *Remote Sensing* 10(5) 714. <https://doi.org/10.3390/rs10050714>
- Upadhyay, V. & Kumar, A. (2018) Hyperspectral remote sensing of forests: technological advancements, opportunities and challenges. *Earth Science Informatics* 11(4) 487–524. <https://doi.org/10.1007/s12145-018-0345-7>
- Valbuena, R. (2015) Forest structure indicators based on tree size inequality and their relationships to airborne laser scanning. *Dissertationes Forestales* 205. <http://dx.doi.org/10.14214/df.205>.
- Vallecillo, S., Maes, J., Teller, A., Babí Almenar J., Barredo, J.I., Trombetti, M., Abdul Malak, D., Paracchini M. L., Carré, A., Addamo A. M., Czúcz, B., Zulian, G., Marando F., Erhard, M., Liqueste, C., Romao, C., Polce, C., Pardo Valle, A., Jones, A., Zurbaran-Nucci, M., Nocita, M., Vysna, V., Cardoso A. C., Gervasini, E., Magliozzi, C., Baritz, R., Barbero, M., Andre V., Kokkoris, I.P., Dimopoulos, P., Kovacevic, V. & Gumbert, A. (2022) EU-wide methodology to map and assess ecosystem condition. Towards a common approach consistent with a global statistical standard. Publications Office of the European Union, Luxembourg. <https://doi.org/10.2760/13048>

- Vihervaara, P., Auvinen, A. P., Mononen, L., Törmä, M., Ahlroth, P., Anttila, S., Böttcher, K., Forsius, M., Heino, J., Heliölä, J., Koskelainen, M., Kuussaari, M., Meissner, K., Ojala, O., Tuominen, S., Viitasalo, M. & Virkkala, R. (2017) How essential biodiversity variables and remote sensing can help national biodiversity monitoring. *Global Ecology and Conservation* 10, 43–59. <https://doi.org/10.1016/j.gecco.2017.01.007>
- Vihervaara, P., Kullberg, P. & Hurskainen, P. (2019) Biodiversiteetin mittaaminen ja uudet menetelmät. *Futura* 38(3) 16–27.
- Viinikka, A., Hurskainen, P., Keski-Saari, S., Kivinen, S., Tanhuanpää, T., Mäyrä, J., Poikolainen, L., Vihervaara, P. & Kumpula, T. (2020) Detecting European aspen (*Populus tremula* L.) in boreal forests using airborne hyperspectral and airborne laser scanning data. *Remote Sensing* 12(16) 2610. <https://doi.org/10.3390/rs12162610>
- Virkkala, R., Leikola, N., Kujala, H., Kivinen, S., Hurskainen, P., Kuusela, S., Valkama, J. & Heikkinen, R. K. (2022) Developing fine-grained nationwide predictions of valuable forests using biodiversity indicator bird species. *Ecological Applications* 32(2) e2505. <https://doi.org/10.1002/eap.2505>
- Wehr, A. & Lohr, U. (1999) Airborne laser scanning – an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing* 54, 68–82. [http://dx.doi.org/10.1016/S0924-2716\(99\)00011-8](http://dx.doi.org/10.1016/S0924-2716(99)00011-8)
- Wallace, L., Lucieer, A., Malenovský, Z., Turner, D. & Vopěnka, P. (2016) Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. *Forests* 7(3) 62. <https://doi.org/10.3390/f7030062>
- White, J. C., Wulder, M. A., Vastaranta, M., Coops, N. C., Pitt, D. & Woods, M. (2013) The utility of image-based point clouds for forest inventory: A comparison with airborne laser scanning. *Forests* 4, 518–536. <http://dx.doi.org/10.3390/f4030518>
- White, J. C., Coops, N. C., Wulder, M. A., Vastaranta, M., Hilker, T. & Tompalski, P. (2016) Remote sensing technologies for enhancing forest inventories: A review. *Canadian Journal of Remote Sensing* 42(5) 619–641. <https://doi.org/10.1080/07038992.2016.1207484>
- Ympäristöministeriö (2024) EU:n biodiversiteetti-strategia. <https://ym.fi/eu-n-biodiversiteetti-strategia> 26.2.2024.
- Yrttimaa, T., Saarinen, N., Luoma, V., Tanhuanpää, T., Kankare, V., Liang, X., ... & Vastaranta, M. (2019) Detecting and characterizing downed dead wood using terrestrial laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing* 151, 76–90. <https://doi.org/10.1016/j.isprsjprs.2019.03.007>
- Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., Xu, H., Tan, W., Yang, Q., Wang, J., Gao, J. & Zhang, L. (2020). Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sensing of Environment* 241, 111716. <https://doi.org/10.1016/j.rse.2020.111716>