



Lauri Korhonen<sup>1</sup>, Kalle Kärhä<sup>1</sup>, Matti Maltamo<sup>1</sup>, Jukka Malinen<sup>2</sup>, Juha Hyyppä<sup>3</sup>, Harri Kaartinen<sup>3</sup>, Janne Toivonen<sup>4</sup>, Petteri Packalen<sup>5</sup> ja Matti Koivula<sup>6</sup>

## Kaukokartoitus ja metsäkoneiden sensorit metsien monimuotoisuusindikaattorien seurannassa

Korhonen L., Kärhä K., Maltamo M., Malinen J., Hyyppä J., Kaartinen H., Toivonen J., Packalen P., Koivula M. (2024). Kaukokartoitus ja metsäkoneiden sensorit metsien monimuotoisuusindikaattorien seurannassa. Metsätieteen aikakauskirja 2024-23010. Katsaus. 36 s. <https://doi.org/10.14214/ma.23010>

### Tiivistelmä

Tässä kirjallisuuskatsauksessa tarkastellaan, millaista metsien monimuotoisuutta kuvaavaa tietoa voidaan saada nykyaikaisen kaukokartoitus- ja sensoritekniikan avulla. Käsittely keskittyy Suomeen, Ruotsiin ja Norjaan, missä metsät, ilmasto-olot ja teknologiset valmiudet sekä käytetyt teknologiat ovat samankaltaisia. Laserkeilaimia ja kuvantavia monikanavasensoreita voidaan asentaa monenlaisille liikkuville alustoille: satelliitteihin, lentokoneisiin, drooneihin ja metsäkoneisiin. Mitä lähempää kohdetta havainnoidaan, sitä tarkempaa tietoa saadaan, mutta sitä pienempi on myös kerralla havainnoitu pinta-ala. Yleisesti käytetyistä monimuotoisuuden indikaattoreista suurikokoisten säästöpuiden määrää, puuston eri-ikäisrakenteisuutta ja vesistöjen suojavyöhykkeitä voidaan havainnoida suhteellisen luotettavasti Suomessa laajalti saatavilla olevilla lentolaserkeilausaineistoilla. Lahopuun ja vähälukuisten puulajien, kuten haavan (*Populus tremula* L.), tunnistaminen onnistuu tällä hetkellä esimerkiksi droonien avulla pienille alueille kerrallaan, mutta riittävän tarkan tiedon saaminen suuralueille vaatii nykyistä tarkemman tekniikan käyttöönottamista lentokoneilla tehtävissä kartoituksissa. Tietyille eläin- ja kasvilajeille sopivia elinympäristöjä voidaan kartoittaa suuriltakin alueilta, mutta esimerkiksi pintakasvillisuudesta ei käytännössä vielä saada riittävän tarkkoja suoria havaintoja. Kaukokartoitus soveltuu kuitenkin hyvin maastoinventointien kohdentamiseen oikeisiin paikkoihin. Metsäkonetietoa hyödyntämällä on mahdollista dokumentoida hakkuissa tehdyt tekopökkelöt ja säästöpuuryhmän tai muun käsittelemättömän alueen, esimerkiksi vesistön tai pienveden suojavyöhykkeen, avainbiotoopin, suojeltavan alueen tai riistatiheikön ympäriltä hakatut rungot. Hyödynnettäessä metsäkonetietoa metsäluonnon monimuotoisuuden mittaamisessa ja seurannassa tärkein asia juuri nyt on parantaa hakkuukoneen hakkuulaitteen sijaintitiedon tarkkuutta anturoimalla hakkuukoneen puomi. Tulevaisuudessa tavoitteena on oltava automatisoitu metsäluonnon monimuotoisuuden mittaaminen ja dokumentointi puunkorjuuoperaatioiden yhteydessä, mikä edellyttää metsäkoneen sensorointia. Tarkan, automatisoidun monimuotoisuustiedon tuottaminen metsäkoneissa olevilla sensoreilla on todennäköisesti mahdollista toteuttaa tällä vuosikymmenellä. Yhteenvetona kaukokartoitus- ja sensoritekniikka mahdollistaa tulevaisuudessa huomattavasti nykyistä tarkemman metsien monimuotoisuutta kuvaavan tiedon keräämisen myös suuralueilta. Tarkimpaan lopputulokseen päästään yhdistämällä useista eri lähteistä peräisin olevia tietoja.

**Asiasanat** biodiversiteetti; droonit; hakkuukoneet; laserkeilaus; luonnon monimuotoisuus; metsäkoneet; metsänarviointi

**Yhteystiedot** <sup>1</sup>Itä-Suomen yliopisto, Metsätieteiden osasto, Joensuu; <sup>2</sup>Metsäteho Oy, Vantaa; <sup>3</sup>Paikkatietokeskus FGI, Espoo; <sup>4</sup>Luonnonvarakeskus, Biotalous ja ympäristö, Joensuu; <sup>5</sup>Luonnonvarakeskus, Biotalous ja ympäristö, Helsinki; <sup>6</sup>Luonnonvarakeskus, Luonnonvarat, Helsinki  
**Sähköposti** lauri.korhonen@uef.fi

**Hyväksytty** 3.6.2024

# 1 Johdanto

Suomessa kerätään metsävaratietoa kahta eri käyttötarkoitusta varten. Suomen metsäkeskus ylläpitää metsätalouden suunnittelun tueksi valtakunnallista kuviotietokantaa, joka sisältää tärkeimmät puustotiedot kuten tilavuuden, pohjapinta-alan ja pituuden puulajeittain. Luonnonvarakeskuksen toteuttama valtakunnan metsien inventointi (VMI) tuottaa metsävaroista otanta-inventointiin perustuvia tilastotietoja, joita hyödynnetään valtakunnallisessa ja maakuntatason päätöksenteossa.

Monimuotoisuuden huomioiminen metsätaloudessa edellyttää monimuotoisuustiedon – etenkin lajistolle tärkeiden puustorakenteiden ja luontotyyppien sekä lajien ja niiden runsauksien – sisällyttämistä metsävaroja kuvaaviin tietokantoihin. Monimuotoisuutta pitäisi pohjimmiltaan arvioida suoraan lajien kokonaismäärää ja erityisesti uhanalaisten lajien määrää mittaamalla (Sodhi ja Ehrlich 2010), mutta lajistotiedon kerääminen maastomittauksilla on kallista ja vaatii erityisosaamista, jota metsäammattilaisilla ei yleensä ole. Tämän vuoksi monimuotoisuuden huomiointi metsäsuunnittelussa on käytännössä toteutettava erilaisiin indikaattoreihin perustuen. Indikaattori on toimiva, jos se kuvaa ympäristön laatua luotettavasti eri lajiryhmien, varsinkin uhanalaisten lajien, kannalta ja sen avulla voidaan arvioida erilaisten ohjauskeinojen vaikutuksia (Halme ym. 2022). Metsätalouden näkökulmasta indikaattorien tulee mahdollistaa monimuotoisuuden kehittymisen seuranta yksittäisten metsikkökuvioiden tasolta aina valtakunnan tasolle asti.

Kaukokartoitus tarkoittaa tässä katsauksessa metsän havainnointia ylhäältä päin sähkömagneettista säteilyä havaitsevien sensorien avulla. Esimerkiksi ilmakuvaus ja lentolaserkeilaus ovat Suomessa yleisesti käytettyjä kaukokartoitusmenetelmiä. Suomen metsäkeskuksen metsävaratiedon keruu perustuu kaukokartoituksen ja maastossa tehtävien koealamittausten hyödyntämiseen, sillä aiempi pelkästään kuviotason maastomittauksiin perustuva metsien inventointijärjestelmä oli kallis ja tarkkuudeltaan riittämätön (Maltamo ym. 2021). Kaukokartoituspohjaisessa metsänarvioinnissa metsikkökuvioita ei yleensä tarkasteta maastossa ollenkaan, vaan puustotiedot johdetaan kaukokartoitusaineistoista tilastollisten mallien avulla. Näillä näkymin kuviotason puustotiedon tuotannossa ei ole paluuta laajamittaiseen maastossa tehtävään inventointiin, vaan maastomittaukset rajoittuvat mallinnuksen tueksi tehtäviin koealamittauksiin ja hakkuukoneiden puunkorjuun yhteydessä tuottamaan mittaustietoon. Tästä syystä myös kuviotason luontotietoa on jatkossa tuotettava yhä enemmän kaukokartoituksen ja hakkuukoneiden tuottaman paikkatiedon avulla. Monimuotoisuuden seurannassa tulisi siis hyödyntää mahdollisimman paljon sellaisia indikaattoreita, joiden havaitseminen on teknisesti mahdollista kaukokartoituksen ja hakkuukoneiden sensoreiden avulla.

Suomen metsien monimuotoisuuden kuvaamiseen yleisimmin käytettyjä indikaattoreita ovat:

- Säästöpuiden määrä ja laatu (puulaji, elävä vai kuollut, järeys).
- Lahopuun tilavuus, järeys, puulaji ja lahon aste erikseen pysty- ja maalahopuille.
- Harvinaiset tai verrattain vähälukuiset puulajit, erityisesti haapa (*Populus tremula* L.).
- Vanhojen ja suurikokoisten puiden määrä ja puulaji sekä metsän eri-ikäisrakenteisuus.
- Arvokkaat elinympäristöt, esimerkiksi lehdot, paahderinteet ja metsien avainbiotoopit.
- Vesistöjen ja pienvesien luonnontilaisuus ja niiden reunoille jätetyt suojavyöhykkeet.
- Valittujen lajien elinympäristöt, lajien kokonaisrunsaus ja uhanalaisten lajien runsaus.

Kaukokartoituksen avulla näiden indikaattorien tilasta voidaan saada paikallista karttamuo-  
toista tietoa, mikä mahdollistaa luontotiedon sisällyttämisen metsätalouden päätöksentekoon kuvio-  
ja tilatasoilla. Kaukokartoitusaineistojen pohjalta voidaan myös laskea uudenlaisia indikaattoreita,  
jotka perustuvat suoraan erilaisilla sensoreilla tehtäviin mittauksiin. Kaukokartoitettu monimuo-  
toisuustieto ei kuitenkaan ole yhtä luotettavaa kuin maastossa mitattu, vaan sen tarkkuus riippuu

siitä, miten helposti kohde on havaittavissa ilmasta käsin. Jos puiden latvukset estävät näkyvyyttä kohteeseen, kuten esimerkiksi maalahopuun tapauksessa usein käy, kohteesta ei välttämättä saada ollenkaan suoria havaintoja. Hakkuukoneisiin asennettavat sensorit taas tuottavat paikallisia mitauksia, mutta niiden avulla saatava tieto ei ole alueellisesti kattavaa. Valtakunnallisen tason luotettavaa tilastotietoa metsien monimuotoisuudesta ei siis kannata tuottaa kaukokartoituksella, vaan sitä on tarkoituksenmukaista kerätä esimerkiksi VMI:n tai muiden kasvillisuusinventointien (esim. Operaatio Mustikka; <https://www.luke.fi/fi/projektit/operaatio-mustikka>) yhteydessä tilastollisella otannalla valituilta maastokoealoilta.

Koeala- ja hakkuukonemittaukset voivat tuottaa tarkkaa tietoa alueelta, johon mittaus kohdistuu. Kaukokartoituksella voidaan kuitenkin kattaa huomattavasti laajempia alueita kuin metsäkonetiedolla, joka rajoittuu metsiköihin, joissa on suoritettu hakkuuta. Kaukokartoitusta voidaan soveltaa aineistosta riippuen eri mittakaavoissa aina kuviotasosta valtakunnalliseen tasoon asti. Jos monimuotoisuuden indikaattoreita voidaan kaukokartoittaa riittävän tarkasti, saadaan samalla myös tietoa esimerkiksi indikaattorien kuvaamien elinympäristöjen kytkeytyneisyydestä ja pirstoutumisesta. Tämä tieto on erityisen arvokasta, sillä sen avulla voidaan kohdentaa monimuotoisuutta turvaavia toimenpiteitä alueille, joilla niistä saadaan suurin hyöty.

Suomen metsäkeskus hyödyntää kaukokartoitusta myös lainvalvonnan tukena. Vuodesta 2020 lähtien käytössä on ollut satelliittikaukokartoitukseen perustuva avohakkuiden valvonta, jonka avulla voidaan tunnistaa hakkuuta, joista ei ole tehty metsänkäyttöilmoitusta. Verrattaessa havaittuja hakkuualueita sijainniltaan tunnetuihin avainbiotooppeihin, voidaan paikantaa kohteita, joissa metsälakia on mahdollisesti rikottu. Nämä kohteet tarkastetaan paikan päällä joko maastotyönä tai dronilla lähietäisyydeltä kerätyn tarkan kuvamateriaalin avulla.

Maa- ja metsätalouden monimuotoisuuden hahmottamisen avuksi on esitetty myös lista ns. olennaisista monimuotoisuuspiirteistä (GEO BON 2023). Englanniksi tämä lista tunnetaan nimellä ”Essential Biodiversity Variables” ja suomeksikin voidaan puhua lyhyesti EBV-piirteistä. EBV-piirteet pyrkivät kuvaamaan luonnon monimuotoisuutta kokonaisuutena ja huomioimaan sen eri osa-alueet. Listalle kuuluu tällä hetkellä 21 piirrettä, jotka on jaettu kuuteen luokkaan: 1) geneettinen monimuotoisuus, 2) lajit ja populaatiot, 3) lajien ominaispiirteet, 4) eliöyhteisöjen rakenne, 5) ekosysteemien toiminta ja prosessit sekä 6) ekosysteemien rakenne (Vihervaara ym. 2019). Euroopan tasolla on tällä hetkellä käynnissä EU:n komission rahoittama EUROPA BON -hanke (European Biodiversity Observation Network), jonka tavoitteena on kehittää EU-tason monimuotoisuuden seuranta. Tämän työn yhteydessä määritellään, mitä indikaattoreita eri EBV-luokkien ja piirteiden seurantaan voidaan sisällyttää, huomioiden että raportoinnin on oltava mahdollisimman yhtenäistä erityyppisille ekosysteemeille. Jatkossa näitä EBV-piirteitä kuvaavia indikaattoreita tullaan myös raportoimaan jäsenmaista Euroopan komissiolle. EBV-piirteiden ja niitä kuvaavien indikaattorien määrittely kaukokartoituksen avulla on tällä hetkellä myös aktiivinen tutkimusaihe (Reddy ym. 2021; Skidmore ym. 2021).

Tässä katsauksessa selvitetään kaukokartoituksen ja metsäkonetiedon käyttökelpoisuutta metsien monimuotoisuutta kuvaavien indikaattorien tulkinnessa. Keskitymme Suomeen sekä osittain Ruotsiin ja Norjaan, joiden ilmasto, maaperä sekä teknologiset valmiudet ovat samantyyppisiä. Käsittelemme erityisesti menetelmiä, joilla monimuotoisuutta voitaisiin arvioida talousmetsissä, ja pyrimme helpottamaan monimuotoisuustiedon tuomista osaksi kuviotasoon metsävaratietoa ja metsätalouden suunnittelua. Arvioimme tutkimuskirjallisuuden ja haastattelujen perusteella tähän soveltuvien teknisten menetelmien käyttökelpoisuutta monimuotoisuuden seurannassa. Näiden tarkastelujen pohjalta ehdotamme, miten kaukokartoituksen ja metsäkonetiedon avulla toteutettava metsien monimuotoisuuden seuranta voitaisiin jatkossa edistää tutkimuksen keinoin ja viedä tutkimustuloksia entistä enemmän käytäntöön.

## 2 Aineistot ja menetelmät

Metsien monimuotoisuuden kaukokartoitusta on tutkittu maailmalla runsaasti. Kirjallisuutta valittaessa keskityttiin lähinnä Pohjoismaissa tehtyyn tutkimukseen, sillä esimerkiksi Keski-Euroopassa ja Pohjois-Amerikassa luonnonolot ja lajisto poikkeavat Pohjoismaista. Myös muualla tehtyä kirjallisuutta hyväksyttiin mukaan, jos tiettyä aihetta ei ole tutkittu Pohjoismaissa. Kaukokartoitusmenetelmistä painotettiin lentolaserkeilausta, ilmakuvausta ja droonisovelluksia, sillä niillä on suurin potentiaali kuviotason monimuotoisuustiedon tuotannossa. Tätä katsausta täydentäviä kansainvälisiä, metsien monimuotoisuuden kaukokartoitusta eri näkökulmista käsitteleviä kokoomajulkaisuja on useita (esim. Reddy 2021; Rocchini ym. 2022; Toivonen ym. 2023). Metsäkoneteknologian osalta julkaisutilanne ei ole yhtä hyvä, ja siksi katsauksessa hyödynnettiin myös muita kuin vertaisarvioituja lähteitä. Kirjallisuuskatsaus tehtiin pääosin aikavälillä 1.1.–30.4.2023. Pääosa katsauksen hyväksytyistä julkaisuista on ilmestynyt kymmenen viime vuoden aikana, joskin tarvittaessa on viitattu myös tätä varhaisempiin alkuperäislähteisiin.

Kirjallisuutta haettiin eri tietokannoista (mm. Google Scholar ja Scopus) sekä internetin hakukoneista aiheenmukaisilla suomen- ja englanninkielisillä hakusanoilla ja niiden yhdistelmillä, kuten ”lahopuun kaukokartoitus” tai ”haapojen tunnistaminen”. Lisäksi tarkasteltiin julkaisujen lähdeluetteloja ja avainjulkaisuihin eri tietokannoissa tehtyjä viittauksia, sekä hyödynnettiin kirjoittajien tietoja alan tärkeimmistä tutkijoista ja tutkimusryhmistä. Kirjallisuuden aukkoja täydennettiin haastatteluilla, joiden kautta katsaukseen saatiin mukaan myös sellaista käytännön tietoa ja näkemystä, jota ei ole saatavilla tieteellisestä kirjallisuudesta. Kaukokartoituksen osalta haastattelut keskittyivät metsäkeskuksen tuoreimpiin inventointikäytäntöihin ja EBV-piirteiden seurannan toteuttamiseen Suomessa. Metsäkonevalmistajien haastatteluissa selvitettiin millä aikajänteellä eri teknologioita voidaan ottaa käyttöön metsäluonnon monimuotoisuuden mittaamisessa.

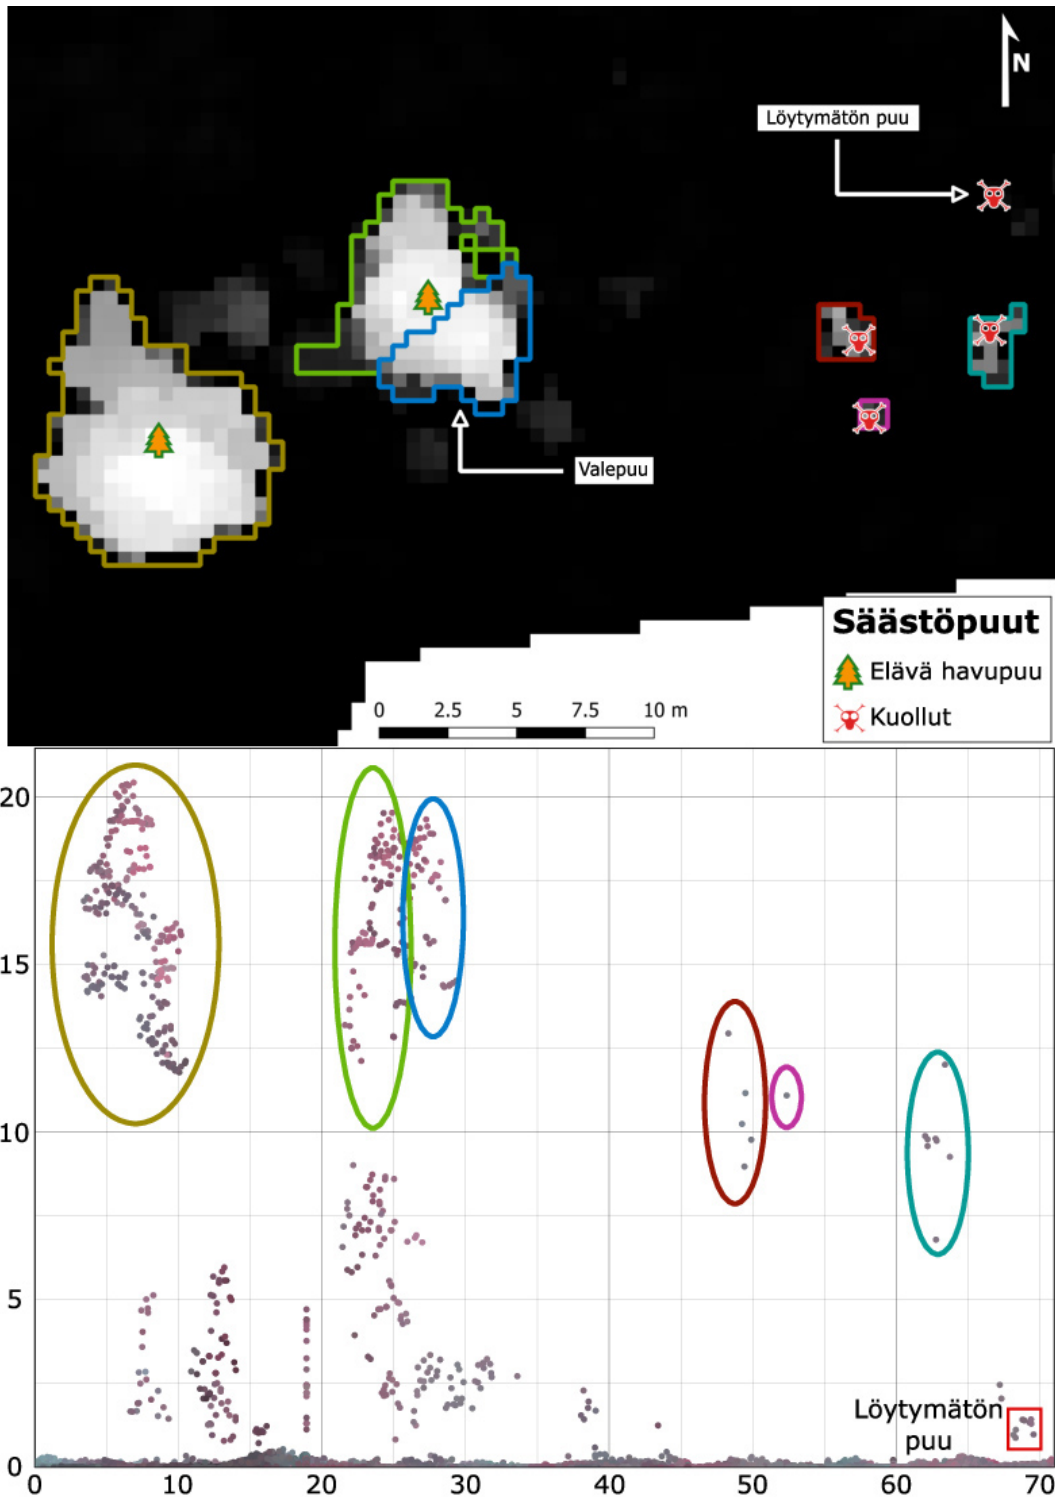
Katsauksemme sisältö on jaettu varsinaiseen tekstiin ja kahteen liitteeseen. Liitteessä L1 (saatavissa osoitteessa <https://doi.org/10.14214/ma.23010>) käsitellään yleisellä tasolla kaukokartoituksen ja metsäkoneiden sensoritekniikkaa, kuten laserkeilausta sekä ilma-, drooni- ja satelliittikuvausta. Samoin liitteessä L1 esitellään kaukokartoitusaineistojen tärkeimmät tulkintamenetelmät, kuten puiden tunnistaminen pistepilviaineistosta ja puustotunnusten ennustaminen tilastollisesti. Mikäli sensoritekniikka ja aineistojen analyysimenetelmät eivät ole ennalta tuttuja, voi olla tarpeen perehtyä liitteeseen L1 ennen siirtymistä varsinaiseen lukuun 3. Luvuissa 3 ja 4 on katsauksen pääsisältö, eli monimuotoisuusindikaattorien tulkinta kaukokartoituksen ja metsäkonetekniikan avulla nykyisen tieteellisen tiedon valossa. Liitteessä L2 (saatavissa osoitteessa <https://doi.org/10.14214/ma.23010>) arvioidaan lisäksi osin subjektiivisesti näiden tekniikoiden tulevaisuuden kehitysnäkymiä sekä tiedon soveltamisen kehityskohteita. Lopuksi annetaan ehdotuksia jatkotutkimuksen aiheiksi sekä tehdään yhteenveto tutkimuksen pääjohtopäätöksistä luvuissa 5 ja 6.

## 3 Kaukokartoitus monimuotoisuusindikaattorien seurannassa

### 3.1 Säästöpuut

Säästöpuiden kartoitus ja luokittelu on tehtävissä kaukokartoituksella tuotetuista tarkoista 3D-aineistoista, joista voidaan tunnistaa yksittäisiä puita. Toistaiseksi aihetta on tutkittu lähinnä lentolaserkeilaukseen perustuen. Puiden tunnistuksen tarkkuus riippuu laserkeilausaineiston pisteitiheydestä sekä tulkittavan puun koosta, naapuripuiden koosta ja siitä, onko kyseessä elävä vai kuollut puu (Helenius 2021; Juote 2021; Hardenbol ym. 2023). Suurikokoisten, selvästi muista puista erillään olevien säästöpuiden tunnistustarkkuus on lähellä sataa prosenttia, erityisesti jos

käytössä on tiheydeltään vähintään 5 pulssia  $m^{-2}$  laseraineistoa (Hardenbol ym. 2023). Pienikokoiset säästöpuut, säästöpuuryhmien pienemmät puut ja kuolleet puut jäävät kuitenkin usein löytymättä (kuva 1). Lisäksi erityisesti suurikokoisten lehtipuiden latvukset voivat jakautua automaattisessa tulkinassa useampaan osaan, jolloin syntyy valepuita (kuva 1).



**Kuva 1.** Esimerkki säästöpuiden tulkinasta latvuston korkeusmallista. Kuvassa on kuusi maastossa tulkittua puuta, joista yksi on virheellisesti tulkittu kahdeksi puuksi. Lisäksi yksi pienikokoinen puu on jäänyt löytymättä. Muokattu julkaisusta Hardenbol ym. (2023), CC BY 4.0.



Helenius (2021) ja Juote (2021) tutkivat säästöpuiden tunnistamista noin 1 pulssi  $m^{-2}$  lento-laseraineistosta laaditusta latvuston korkeusmallista. Heleniuksen tutkimuksessa löydettiin 25 % kaikista ja Juotteen tutkimuksessa 69 % elävistä maastossa mitatuista säästöpuista. Heleniuksen tutkimus kohdistui alueelle, jossa kuvioille oli jätetty erikokoisten säästöpuiden ryhmiä ja osa kuvioista oli myöhemmin kulotettu. Kuolleiden ja pienien säästöpuiden osuus alueella oli suuri, mikä selittää alhaista löytymisprosenttia. Juotteen tutkimuskuviot olivat tyypillisiä talousmetsien hakkuualueita, joilla puiden tunnistaminen oli verraten helppoa.

Hardenbol ym. (2023) tutkivat säästöpuiden tunnistusta ja luokittelua käyttäen nykyään laajalti kerättävää 5 pulssia  $m^{-2}$  lentolaseraineistoa ja 27 kuvion maastoaineistoa Suomen metsäkeskuksen Outokummun inventointialueelta. Aineisto sisälsi sekä tuoreita että jo taimettuneita avohakkuu-alueita, ja säästöpuiksi määriteltiin siksi puut, jotka ylsivät laseraineistosta tulkittuna vähintään kolme metriä kasvatettavan puuston yläpuolelle. Elävien säästöpuiden löytymistarkkuudeksi saatiin 84 %. Valepuita löytyi 28 % suhteessa elävien puiden kokonaismäärään. Suurin osa valepuista syntyi suurikokoisten latvusten jakautumisesta useampaan osaan (kuva 1), ja loput olivat ympäristöään pidempiä kasvatettavan jakson puita. Kuolleista säästöpuista löytyi vain 42 %. Pötkelöiden ja muiden latvuksettomien kuolleiden puiden löytyminen todettiin haastavaksi erityisesti silloin, jos alue oli jo taimettunut, sillä 5 pulssia  $m^{-2}$  tiheydellä kaikuja ei välttämättä saatu rungon yläosasta, mikä lisäsi sekoittumista kasvatettavaan puustoon.

Hardenbol ym. (2023) myös luokittelivat löytyneet säästöpuut havu-, lehti- ja kuolleisiin puihin 71 % tarkkuudella. Puulajin luokittelu kaukokartoitukseen perustuen on haastavaa, joten tätä tarkempaa luokitusta ei yritetty aineiston rajallisen määrän takia. Luokituksessa käytettiin apuna myös ilmakuvia, mutta ennusteiden tarkkuus ei parantunut niiden avulla. Puulaji ja kuolleiden puiden lahoamisaste olisivat tärkeää tietoa säästöpuiden ekologisen analyysin kannalta, mutta tätä tietoa ei tällä hetkellä saada kovin tarkasti laajalti saatavilla olevista aineistolähteistä.

Pienalueilla lentolaserkeilausta suurempaan tarkkuuteen voitaisiin todennäköisesti päästä droonien avulla. Drooneilla voidaan kerätä joko laserkeilaus- tai ilmakuva-aineistoa, joka voidaan myös muuntaa yksinpuintulkintaa varten 3D-pistepilveksi fotogrammetrisilla menetelmillä. Droonilaserkeilauksen avulla voidaan nykyään tulkita suoraan puiden runkoja ja niiden järeyksiä (Liang ym. 2019; Kukkonen ym. 2022). Varttuneessa havumetsässä erittäin tiheää pistepilveä (2200–3800 pulssia  $m^{-2}$ ) tuottavan droonilaserkeilauksen avulla löydettiin läpimitaltaan yli 20 cm:n puista 86–96 % ja pienemmistä 30–70 % (Hyyppä ym. 2022). Säästöpuukuviot ovat yleensä varttuneita metsiä helpompia tarkastelukohteita, eli säästöpuiden tapauksessa droonilaserkeilauksella päästään todennäköisesti vielä parempiin tuloksiin puiden tunnistamisessa, ja myös niiden läpimittaa voidaan arvioida suoraan pistepilven perusteella.

Yllä mainituissa tutkimuksissa oletettiin, että kuviot, joilta säästöpuita tulkitaan, tunnetaan etukäteen. Käytännön toiminnassa näin ei välttämättä ole, sillä säästöpuut voivat sekoittaa esimerkiksi siemenpuihin. Siemenpuut on mahdollista erottaa säästöpuista lähinnä vain jätettyjen puiden hehtaarikohtaista määrää tarkastelemalla tai metsänkäyttöilmoituksessa annetun hakkuutavan perusteella. Kuviorajausten on myös oltava niin tarkkoja, ettei viereisten kuvioiden reunapuita tule vahingossa mukaan säästöpuihin.

Säästöpuiksi valittavien puiden on oltava läpimitaltaan PEFC-sertifikaatin mukaan vähintään 15 cm, FSC-sertifikaatin mukaan Etelä-Suomessa 20 cm ja Pohjois-Suomessa 15 cm. Lentolaserkeilauksella löytyneiden säästöpuiden läpimitan ja edelleen tilavuuden arviointi on todennäköisesti epävarmaa, erityisesti kuolleiden ja katkenneiden puiden tapauksessa. Kaukokartoitukseen perustuvan seurannan näkökulmasta säästöpuun pituus olisi helpommin tulkittava suure, mutta järeydellä on pituutta enemmän merkitystä puilla elävälle lajistolle. Vanhemmilla uudistusaloilla lentolaserkeilaukseen perustuva säästöpuiden ja kasvatettavan puuston erottelu on kuitenkin käytännössä tehtävä pituuskriteerin perusteella läpimittatiedon epätarkkuuden takia. Tämän ongelman

välttämiseksi säästöpuiden tulkinta kannattaa suorittaa mahdollisimman pian hakkuun jälkeen, jotta sekoittuminen kasvatettavaan puustoon minimoituu. Aikaisin suoritettu tulkinta mahdollistaa myös säästöpuiden kasvun ja kaatumisen seurannan sitä mukaa kun uutta laserkeilausaineistoa kerätään. Näin voidaan saada tietoa myös säästöpuiden ekologiasta.

Yhteenvetona voidaan todeta, että kaukokartoitus soveltuu parhaiten suurikokoisten elävien säästöpuiden inventointiin. Nämä puut voidaan tunnistaa luotettavasti lentolaserkeilauksella tai drooneilla. Suurikokoiset puut ovat myös ekologisesti arvokkaimpia. Inventoinnin teknisessä toteutuksessa on kuitenkin kiinnitettävä huomiota valepuiden välttämiseen, ettei säästöpuiden määrää yliarvioida. Elävien säästöpuiden puulajia voidaan myös arvioida vähintään karkealla jaolla havu- ja lehtipuihin, mikäli tulkinta-alueelta kerätään soveltuvaa tukiaineistoa. Pienikokoisten elävien ja kuolleiden säästöpuiden sekä säästöpuuryhmien tulkinta on kuitenkin nykyisillä aineistoilla virhealtista. Virheiden vähentämiseen tulisi kiinnittää jatkossa huomiota tutkimuksessa ja käytännön inventoinneissa.

Metsäkeskus toteuttaa ylispuiden operatiivista tulkintaa jo tällä hetkellä laserkeilauksen yksinpuintulkintaan perustuen. Tiedot tallennetaan varsinaisesta kuviotiedosta erilliseen luontotietokantaan. Erillistä puutason tukiaineistoa säästöpuiden luokitteluun ei tällä hetkellä kerätä, mutta varttuneista metsistä kerättävät ns. puukarttakoealat soveltunevat myös säästöpuiden luokittelun tueksi. Ylispuiden luokittelu säästöpuihin ja siemenpuihin on kuitenkin käytännössä ongelmallista. Hakkuualueille jätettävien säästöpuuryhmien ja riistatiheikköjen tulkinta kaukokartoituksen avulla on myös haastavaa, mutta hakkuukonetiedon avulla nämä on mahdollista saada tietoon huomattavasti tarkemmin (luku 4).

### 3.2 Maa- ja pystylahopuu

Kuollut puu, eli lahoppuusto sisältäen pysty- ja maapuut, on yksi keskeisimmistä yleisesti käytössä olevista monimuotoisuusindikaattoreista. Tässä katsauksessa määrittelemme lahoppuun niin, että se sisältää sekä kovan että pehmenneen kuolleen runkopuun. Lahoppuusta kiinnostuksen kohteena olevat tunnuksat sisältävät sen dimensiot (pituus, läpimitta, tilavuus) sekä puulajin ja lahoasteen. Lahoppuuston tarkka maastoinventointi on aikaa vievää. Suurin osa tarkasteltavasta alueesta sisältää yleensä vain pieniä määriä lahoppuuta, ja talousmetsien lahoppukappaleet ovat enimmäkseen pienikokoista hakkuutähdettä. Suomessa lahoppuun maastomittauksia tehdään lähinnä VMI-koealoilla ja suojelualueille keskittyvissä tutkimuksissa. Läpimitaltaan alle 10 cm kokoisia lahoppuun kappaleita mitataan vain harvoin. Lahoppuuston otosinventointiin on kehitetty menetelmiä, jotka ottavat huomioon lahoppuun harvinaisuuden suhteessa elävään puustoon ja sen mahdollisen ryhmittäisen esiintymisen (Kangas 2006; Ståhl ym. 2010; Pesonen 2011). Maastoinventointiaikakaudella kuvioittaisessa arvioinnissa lahoppuuta tarkasteltiin yleensä silmävaraisesti; näin tehtiin esimerkiksi tilavuusluokittaisessa Metsähallituksen inventointisovelluksessa.

Kaukokartoitus tarjoaa uusia mahdollisuuksia lahoppuuston kartoitukseen. Monissa tapauksissa aineisto kattaa koko inventointialueen, ja laserkeilaus tuottaa 3D-informaatiota puuston vertikaalisesta rakenteesta. Lisäksi kaukokartoitusaineistojen aikasarjasta on lähtökohtaisesti nähtävissä myös puiden kuoleminen tai kaatuminen.

Maksuttomasti saatavilla olevien satelliittikuvien erotuskyky ei riitä lahoppuuston erotteiluun, mutta ilmakuvilta voidaan tulkita kuolleita pystypuita visuaalisesti, mikäli niiden latvus on tallella ja niiden asema on vallitsevassa latvuserroksessa (L1 kuva 4). Tällainenkaan lähtökohta ei kuitenkaan ole realistinen suuralueen kartoitukseen. Viime aikoina on tulkittu pystylahoppuuta ilmakuvilta myös automaattisilla menetelmillä (Zielewska-Buttner ym. 2020), joita voidaan soveltaa suuralueille (Li ym. 2023).

Lentolaserkeilauksen aluepohjaisella tulkinnalla eli tilastollisella mallinnuksella on saatu lupaavia tuloksia kansallispuistossa (Pesonen ym. 2008). Tämä koskee niin pysty- kuin maalahopuustoakin. Menetelmä ei kuitenkaan erottele puulajeja tai lahoasteita. Lähestymistapa perustuu puiden kuolemisen ja kaatumisen aiheuttamaan latvusaukkoisuuteen, joka on nähtävissä pysty-puuston (niin elävät kuin kuolleetkin puut) rakenteessa. Vastaava ei kuitenkaan päde talousmetsissä, missä latvusaukkojen taustalla on lähes aina harvennushakkuu. Tutkimuksissa lahoppuuston lentolaserkeilauspohjaisen ennustamisen virhe talousmetsissä on noussut suureksi, eivätkä saadut ennusteet siksi ole olleet käyttökelpoisia (Kotamaa 2007; Maltamo ym. 2014). Vastaavasti lahoppuun määrä on ollut vain  $3,4 \text{ m}^3 \text{ ha}^{-1}$  Kotamaan (2007) tutkimassa talousmetsässä Sonkajärvellä ja toisaalta  $27,3 \text{ m}^3 \text{ ha}^{-1}$  Kolin kansallispuistossa. Aluepohjaisesti ei ole myöskään kyetty löytämään talousmetsissä erittäin harvinaisia lahoppuuskertymiä.

Laserkeilausaineiston yksinpuintulkinta tarjoaa lähtökohtaisesti luonnollisemman tavan lahoppuuston havainnointiin. Pystypuut voidaan luokitella eläviksi ja kuolleiksi, ja aikasarjan avulla nähdään tapahtuneet muutokset (Tanhuanpää ym. 2015). Tässäkin tutkimuksessa ilmiötä havainnoitiin lähinnä erilaisilla suojelualueilla. Potentiaalinen tunnus erottelemaan eläviä ja kuolleita pystypuita on puun latvuksen leveyden suhde sen pituuteen (Hardenbol ym. 2023; Huo ym. 2023). Yksinpuintulkintaan voidaan myös yhdistää ilmakuvista saatavaa sävyarvotietoa, joka helpottaa puiden luokittelua eläviin ja kuolleisiin. Norjassa on saatu tällä lähestymistavalla lupaavia tuloksia suurikokoisten pystyyn kuolleiden puiden tulkinnassa (Jutras-Perreault ym. 2023).

Pystylahoppuun yksinpuintulkintaa on tutkittu myös droonianeistosta. Tulkitun lahoppuun tilavuuden ja runkoluvun prosentuaaliset virheet olivat suuria suomalaistutkimuksessa, joka hyödynsi fotogrammetristen pistepilvien pohjalta tehtyä yksinpuintulkintaa (Saarinen ym. 2018). Sen sijaan tulkittaessa suurikokoisia pystyyn kuolleita puita droonikuvamosaiikeista syväoppivien neuroverkkojen avulla päästiin parempiin tuloksiin, kun samoja menetelmiä sovellettiin sekä Saksassa että Suomessa (Schiefer ym. 2023).

Lentolaserkeilauksen käytöstä on saatu lupaavia tuloksia suurten maalahoppuiden kartoituksessa (Heinara ym. 2021; Huo ym. 2023). Menetelmä perustuu vaakasuorien linjamaisten rakenteiden suoraan tulkintaan laserkeilauksella tuotetuista pistepilvistä; tällaisia rakenteita on aiemmin tutkittu paikallisesti maalaserkeilauksella (Yrttimaa ym. 2019). Menetelmä edellyttää suurta pulssitiheyttä, vähintään  $15 \text{ pulssia m}^{-2}$ , ja tarkkuus paranee pulssimäärän kasvaessa (Heinara ym. 2023). Sovellettaessa näitä menetelmiä suurille alueille haasteiksi voivat tulla laskennallinen raskaus ja väärin tunnistetut valepuut.

Yksinpuintulkinnan soveltuvuus lahoppuun tunnistamiseen talousmetsissä on pääosin selvittämättä. Työtä on haitannut sopivien tutkimusaineistojen puuttuminen. Toisaalta kasvava piste-tiheys ja aikasarjat mahdollistanevat lähiaikoina tutkimustyön tehostumisen ja monipuolistumisen. Tulkintaan voidaan liittää ilmakuvan sävyarvotietoa laserpistetasolla, jolloin elävien ja kuolleiden pystypuiden luokittelu helpottuu ainakin teoriassa. Kuitenkin täytyy muistaa, että kaukokartoituspohjaisesti lahoppuuston luokittelu puulajeittain ja edelleen lahoasteittain on haastavaa ja jouduttaneen tyytymään karkeisiin luokkiin. Yhteenvetona todettakoon, että lahoppuuston kaukokartoitus riittävällä tietosisällöllä ja riittävän tarkasti on haasteellista, mutta toisaalta ilmakuva- ja laserkeilausaineistojen tarkkuuden jatkuva paraneminen tarjoaa mahdollisuuksia tulkinnan parantamiseen.

### 3.3 Monimuotoisuuden kannalta tärkeät puulajit

Suomessa kaikki harvalukuiset lehtipuulajit, kuten haapa, ylläpitävät yleisimmistä puulajeista poikkeavaa lajistoa ja ovat siksi monimuotoisuuden kannalta arvokkaita (Keto-Tokoi ja Siitonen 2021). Tällä hetkellä kaukokartoituspohjaisessa metsävaratiedossa harvinaisimmat lehtipuulajit



yhdistetään koivuihin (*Betula pendula* Roth, *Betula pubescens* Ehrh.), sillä niiden määrä ja taloudellinen arvo ovat suhteessa vähäisiä. Tutkimusta puulajitulkinnasta on tehty runsaasti: esimerkiksi eri haapalajien tulkintaa on Pohjoismaiden lisäksi tutkittu myös Keski-Euroopassa ja Pohjois-Amerikassa (Kivinen ym. 2020). Keskitymme tässä katsauksessa kuitenkin vain Pohjoismaihin. Boreaalisen kasvillisuusvyöhykkeen ulkopuolella monimuotoisuuden kannalta tärkeät puulajit vaihtuvat, ja esimerkiksi tropiikissa yksittäisten puulajien sijasta kiinnostuksen kohteena voi olla puulajien kokonaislukumäärä tiettyä pinta-alayksikköä kohden.

Aluksi puulajiluokituksia tehtiin pelkästään ilmakuviin sävyarvotietoihin perustuen. Erikson (2004) segmentoi latvuksia suoraan ilmakuvilta ja luokitteli männyn (*Pinus sylvestris* L.), kuusen (*Picea abies* (L.) H. Karst.), koivun ja haavan erillisiin luokkiin segmenttien muotojen ja sävyarvojen perusteella. Haavan osalta tässä Ruotsissa tehdyssä tutkimuksessa päästiin 67 % tarkkuuteen. Myöhemmin puulajiluokitusta on tehty lentolaserkeilauksella tai laserkeilauksen ja ilmakuviin yhdistelmillä (esim. Ørka ym. 2007; Säynäjoki ym. 2008; Viinikka ym. 2020). Haapojen tunnistamisen tekee haastavaksi haavan latvus rakenne. Latvus voi olla hyvin laaja ja sisältää useita paikallisia korkeusmaksimeita. Tällöin latvus pirstoutuu segmentoinnissa helposti useammaksi pienemmäksi palaksi, jotka tunnistetaan erillisinä valepuina. Haavan erottelu muista lehtipuista edellyttää laseraineiston täydentämistä erotuskyvyltään riittävällä optisella kuvamateriaalilla (Saarinen ym. 2018; Viinikka ym. 2020; Mäyrä ym. 2021).

Puulajiluokittelua varten laseraineistosta on yleisesti laskettu korkeus- ja tiheyspiirteiden lisäksi intensiteettitunnuksia. Korpelan ym. (2010) mukaan haavan intensiteettiarvot sekoittuvat koivun ja kuusen kanssa. Puulajiluokittelussa on myös hyödynnetty erilaisia koneoppimismenetelmiä. Uusimpien tutkimusten perusteella tukivektorikoneet sekä syväoppivat neuroverkot ovat lupaavimpia luokittelijoita (Viinikka ym. 2020; Mäyrä ym. 2021). Parhaimmillaan haavan kohdalla on päästy 83 km<sup>2</sup> laajuudella sekä luonnon- että talousmetsiä sisältävällä tutkimusalueella 91 % tunnistustarkkuuteen, kun käytössä on lentolaserdatan lisäksi ollut hyperspektrikameralla tuotettuja ilmakuvia (Mäyrä ym. 2021). Kaikujen lisäksi myös palaavan pulssin aaltomuodon tallentavalla kahden kanavan (1064 ja 1550 nm) laserkeilaimella on päästy paikallisesti tarkkoihin tuloksiin haavan ja tervalepän (*Alnus glutinosa* (L.) Gaertn.) luokituksessa (Korpela ym. 2023), mutta tällaista aineistoa ei toistaiseksi ole saatavilla laajoilta alueilta.

Yksinpuintulkintaa hyödynsivät myös Toivonen ym. (2024) Metsäkeskuksen Mikkelin inventointialueella, jossa suuri osa koelaloista sijaitsi talousmetsissä. Tavoitteena oli tunnistaa suuria, läpimitaltaan > 22 cm haapoja hyödyntämällä laser- ja ilmakuva-aineistoja. Näin määritellyjä haapoja oli aineistossa vain 35 (0,1 % kaikista puista), ja niistä pystyttiin parhaimmillaan tunnistamaan seitsemän, mikä vastasi 20 % kaikista suurista haavoista. Tutkimuksessa testattiin myös eri läpimittarajoja suurten haapojen luokittelussa, ja parhaimmillaan noin 32 % suurista haavoista tunnistettiin onnistuneesti, kun suuren haavan läpimittarajana oli 26 cm.

Yksinpuittaisen lähestymistavan lisäksi on tutkittu myös haavan liittämistä osaksi kaukokartoitus pohjaista kuviotason metsävaratietoa (Breidenbach ym. 2010; Pippuri ym. 2013). Tarkkuus on toistaiseksi ollut huono johtuen vaikeuksista erotella koivua ja haapaa sekä etenkin siitä, että haapaa on yleensä hyvin vähän, jolloin sen suhteellinen ennustevirhe nousee helposti korkeaksi.

Vaikka yksinpuintulkinnassa onkin parhaimmillaan päästy sängen hyviin tuloksiin, täytyy muistaa, että tutkimukset on yleensä tehty niin puiden lukumäärän kuin maantieteellisen vaihtelunkin osalta suppeilla aineistoilla. Lisäksi tutkimusalueet ovat usein olleet erilaisia suojelualueita, joilla haavan esiintyminen on talousmetsää runsaampaa. Onkin odotettavissa, että laaja-alainen haapatulkinta talousmetsissä on huomattavasti haastavampaa. Lisäksi haapojen onnistunut segmentointi edellyttää tavallisesta yksinpuintulkinnasta poikkeavia ratkaisuja, eikä siten ole helposti liitettävissä muuhun suuraluetason tulkintaan. Kivisen ym. (2020) kokoomajulkaisuun on kerätty siihenastinen tietämys haavan kaukokartoitus pohjaisesta tulkinnasta.

Drooniaineistot soveltuvat myös erinomaisesti harvinaisten puulajien tulkintaan. Tuominen ym. (2018) luokittelivat 26 eri puulajia Mustilan arboretumista droonilla kerättyjen RGB- ja hyperspektrikuvien spektriarvojen ja 3D-pistepilvipiirteiden avulla. Luokittelussa päästiin monien harvinaistenkin puusukujen osalta hyviin tuloksiin: esimerkiksi haavalle tarkkuus oli 73 %, vaahteralle (*Acer platanoides* L.) 80 %, saarnelle (*Fraxinus excelsior* L.) 82 % ja tammille (*Quercus robur* L. ja *Quercus rubra* L.) 88 %. Saarisen ym. (2018) niin ikään yksinpuintulkintaa ja hyperspektrikuvausta yhdistäneessä droonitulkinnessa haavan ja lepän tilavuutta kuitenkin yliarvioitiin, ja niiden tilavuuksien ennustettu tarkkuus jäi selvästi heikommaksi kuin kolmen yleisemmän puulajin.

Hämeenlinnan Evolla tehdyssä tutkimuksessa haavan tunnistamisessa päästiin parhaimmillaan 86 %:n tarkkuuteen yhdistelemällä droonilla kesäaikaan kerättyjä RGB- ja monikanavakuvien sävyarvoja (Kuzmin ym. 2021). Vastaavalla Ilomantsista kerätyllä aineistolla päästiin parhaimmillaan 97 % tarkkuuteen (Hardenbol ym. 2021). Hardenbolin ym. (2021) mukaan haavan tunnistamisessa parhaimmaksi osoittautui 13. toukokuuta kerätty aineisto, jonka keräysaikana koivujen lehdet olivat jo puhjenneet, mutta haavat olivat vielä lehdettömiä. Myös muina ajan-kohtina touko–syyskuussa päästiin 85–95 % tarkkuuksiin. Hyviä tuloksia selittää tutkimusalueen pienuuden lisäksi se, että puut sisältäneet segmentit rajattiin manuaalisesti virheettömiksi. Puita rajaavien segmenttien epätarkkuus on tyypillinen virhelähde puutason kaukokartoituksessa: yksi aineistosta tulkittu puusegmentti voi todellisuudessa sisältää useita puita, mikä johtaa epätarkkuuteen luokittelussa erityisesti silloin, jos kyseiset puut ovat eri lajia. Laaja-alaisissa tulkinnoissa segmentoinnin korjaaminen käsin ei kuitenkaan ole mahdollista, joten tutkimuksessa on jatkossa syytä panostaa segmentointialgoritmien kehittämiseen.

### 3.4 Rakenteellinen monimuotoisuus ja suurikokoiset puut

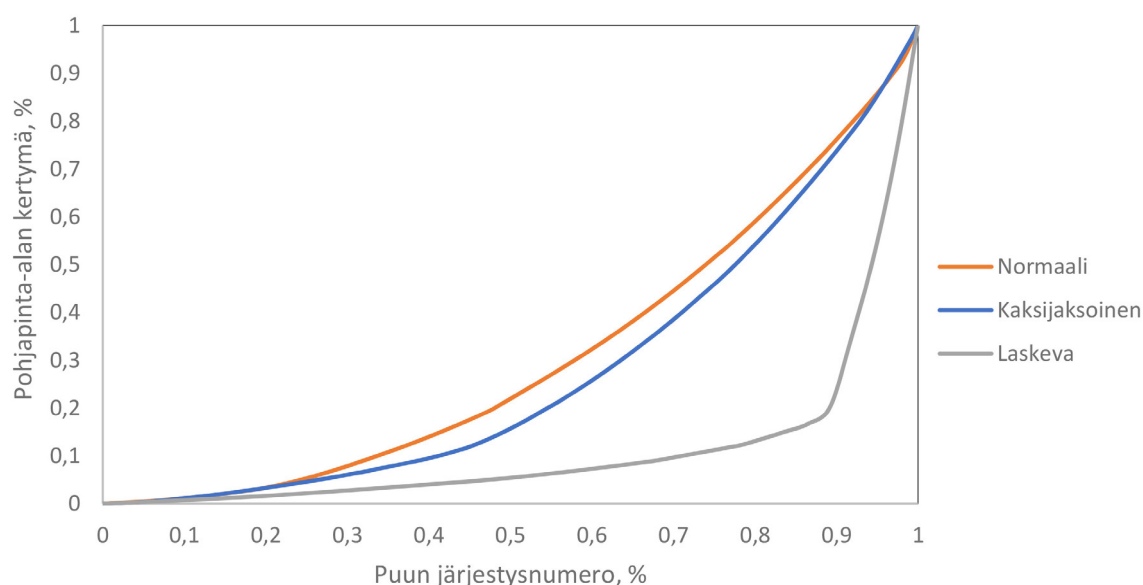
Puuston rakenteellisella monimuotoisuudella tarkoitetaan puulajisuhteita, puuston vertikaalista eli pituuden mukaista vaihtelua sekä toisaalta puuston koko- eli yleensä läpimittajakaumaa. Läpimittajakauma kuvaa yleensä joko puiden lukumäärää tai niiden pohjapinta-alaa valitussa läpimittaluokassa. Lisäksi voidaan erikseen tarkastella suurikokoisia puita. Muita puuston rakenteeseen kuuluvia tunnuksia, kuten lahoppuustoa ja arvokkaita puulajeja, käsitellään muissa alaluvuissa. Puuston vertikaalinen rakenne ja kokojakauma, kuten puun pituus ja läpimitta, ovat myös läheisessä riippuvuussuhteessa. Yleensä vertikaalista rakennetta luokitellaan eli tunnistetaan alempia jaksoja, kun vastaavasti kokojakauma ennustetaan yleensä jatkuvana muuttujana, sillä se muodostaa perustan puuston tilavuuden laskennalle.

Lähtökohtaisesti vain vallitsevan latvuskerroksen omaava, kokojakaumaltaan normaalijakaumaa muistuttava puusto mielletään talousmetsäksi. Tällöin läpimittajakaumassa erottuu vain yksi selkeä huippu. Vähäravinteisimmilla kasvupaikoilla luonnontilainenkin puusto saattaa muistuttaa rakenteeltaan yksihuippuista muotoa. Vastaavasti alempien latvuskerrosten olemassaolo ja kokojakauman useampihuippuisuus tai laskeva muoto (eli eniten puita pienimmissä läpimittaluokissa) mielletään enemmän luonnontilaista puustoa kuvaaviksi rakenteiksi. Esimerkiksi läpimittajakaumaltaan useampihuippuinen männikkö voi kuvastaa metsäpalojen muokkaamaa rakennetta, jossa suurimpia puita on jäänyt palon jälkeen eloon, ja niiden lisäksi on kehittynyt nuorempaa puustoa. Ongelmalliseksi latvusrakenteen käytön monimuotoisuuden indikaattorina tekee se, että useampijaksoisia puustoja esiintyy myös talousmetsissä: esimerkiksi taimikon päällä kasvava verhopuusto tai jopa pelkkä sekametsä, jossa toinen puulaji on toista kookkaampaa, ovat useampijaksoisia. Lisäksi jatkuvan kasvatuksen muodostama puuston rakenne noudattaa ainakin periaatteessa jatkuvaa vertikaalista sekä laskevaa kokojakaumaa. Toisaalta tällaisten metsien osuus on uusimman VMI-tiedon perusteella Suomessa vielä vähäinen (Korhonen ym. 2021).

Lentolaserkeilaukseen perustuvia sovelluksia puuston rakenteen kuvaamiseksi on kehitetty runsaasti eri puolilla maailmaa (Maltamo ym. 2005; Miura ja Jones 2010; Valbuena 2015; Sumnall ym. 2017). Sovellukset voivat perustua suoraan 3D-pistepilveen tai siitä laskettuihin tunnuksiin. Aineistoa voidaan myös luokitella suoraan pisteiden maanpinnan yläpuolisten korkeuksien perusteella. Puuston rakenteen kuvaus onnistuu laserkeilauksella ainakin tutkimusolosuhteissa paremmin kuin monien muiden monimuotoisuustunnusten. Edellytyksenä on se, että keilausaineiston pulsitiheys ja muut keilausparametrit ovat riittäviä, jotta osa pulsseista läpäisee vallitsevan latvuserroksen ja kuvaa siten myös mahdollista alikasvospuustoa. Puuston jaksollisuuden tulkinta ei kuitenkaan yleensä sisälly tyypilliseen laserkeilauspohjaiseen metsäinventointiin, sillä se edellyttää omia menetelmiään.

Eräs viime aikoina sovellettu lähestymistapa on hyödyntää ns. ginikerrointa tai graafisesti Lorenzin käyriä (kuva 2) (Valbuena 2015). Ginikerroin on alun perin kehitetty taloustieteissä kuvaamaan tuloeroja. Puuston rakenteen tapauksessa se lasketaan esimerkiksi puiden pohjapinta-alojen tasaisuuden perusteella. Graafisesti tarkasteltuna erilaiset puustorakenteet ovat eroteltavissa ja niiden ginikertoimia voidaan joko ennustaa laserpiirteillä tai jopa laskea ginikertoimet suoraan laserpiirteistä.

Puuston kokojakauman ennustaminen on perinteisesti ollut tärkeä osa metsänarviointia. Monimuotoisuuteen liittyen myös useampihiippuiset ja laskevat kokojakaumat tulisi pystyä kuvaamaan metsävaratietokannoissa. Lentolaserkeilauspiirteillä tämä on onnistunutkin kohtuullisesti (Bollandsås ja Næsset 2007; Packalén ja Maltamo 2008; Rätty ym. 2020). Täytyy kuitenkin muistaa, että kaukokartoituspiirteillä ennustettaessa osa kohteista menee yleensä aina väärin. Lisäksi hyödynnettäessä laajoja talousmetsäaineistoja, muut kuin yksihiippuiset puustorakenteet ovat harvinaisia, ja niiden tunnistaminen on haastavampaa kuin rajatuissa tutkimusaineistoissa. Haastavinta kokojakaumien ennustaminen on tilanteissa, joissa tieto tarvitaan puulajeittain. Tällöin tarvitaan laserkeilauksen lisäksi myös erotuskyvyllään riittävän tarkkaa optista kaukokartoitusmateriaalia, eikä puulajitasolla ennustaminen ole siltikään ollut kovin tarkkaa (Packalén ja Maltamo 2008).




**Kuva 2.** Esimerkki erilaisia puustorakenteita kuvaavista Lorenzin käyristä. Normaali muoto indikoi tasarakenteista talousmetsää, kaksijaksainen luonnontilaisuutta ja laskeva eri-ikäisrakenteisuutta.

Jos käytävissä on vain yksinpuintulkintaan sopimatonta harvaa laserkeilausaineistoa, suurikokoisten puiden kappalemäärää eri läpimittaluokissa voidaan mallintaa myös aluepohjaista menetelmää käyttäen. Korhonen ym. (2016) ennustivat yli 35 cm paksujen puiden lukumäärää aluepohjaisesti käyttäen Kaakkois-Norjasta kerättyä aineistoa, ja pääsivät mallinnuksessa 66 % kokonaistarkkuuteen. Suurikokoisten puiden määrää voidaan ennustaa myös puulajeittaisten runkolukusarjojen kautta (esim. Rätty ym. 2018). Suurten puiden lukumäärää on kuitenkin luontevinta ennustaa käyttämällä yksinpuintulkintaa.

### 3.5 Arvokkaat elinympäristöt ja vanhat metsät

Metsien arvokkaissa elinympäristöissä esiintyy lajistoa, jota tavanomaisista talousmetsistä ei yleensä löydy tai joita tavataan huomattavasti harvemmin. Metsälain 10 §:ssä määritellyt erityisen arvokkaat elinympäristöt ovat pienialaisia, ympäristöstään poikkeavia ja ekologisesti luonnontilaisia tai luonnontilaisen kaltaisia. Näihin kuuluvat mm. pienvedet ja niiden ympäristöt (luku 3.6), tietyt suotyypit, rehevät lehtolaidut, kalliojyrkänteiden alla ja rotkoissa sijaitsevat metsät, sekä erityisen karut ja harvapuustoiset kasvupaikat, kuten kalliometsät ja hietikot. Kaikki arvokkaat elinympäristöt eivät kuitenkaan ole metsälain suojelemia. Esimerkiksi paahdeympäristöt ovat myös lajistoltaan erityislaatuisia. Luonnontilaisen kaltaisia metsiä esiintyy kaikentyyppisillä kasvupaikoilla, ja niiden lajisto riippuu kasvupaikan ominaisuuksista.

Arvokkaiden elinympäristöjen tunnistaminen on usein haastavaa ja vaatii erilaisten paikatieto- ja kaukokartoitusaineistojen yhdistelyä. Jyrkänteet, kurut ja rotkot ovat helpoimmin paikannettavissa, sillä selkeät kohteet on merkitty peruskarttoihin. Maanpinnan korkeusvaihtelun pienemmätkin yksityiskohdat erottuvat selvästi nykyisissä laserkeilauksella laadituissa maanpinnan korkeusmalleissa ja niiden visualisoinneissa (kuva 3) (Paakkari 2023). Suot ja niiden ojitus-



**Kuva 3.** Laserkeilauspohjaisesta korkeusmallista laskettu rinnevarjoste. Kuvassa erottuvat mm. jyrkänteet ja ojat. Lähde: Maanmittauslaitos 02/2023.



tilanne on myös merkitty nykyisiin peruskarttoihin ja maaperää kuvaaviin paikkatietoaineistoihin. Usein näiden peruspaikkatietojen lisäksi tarvittaisiin kuitenkin myös tarkempaa tietoa kohteiden maaperästä, sillä poikkeuksellisen suuri tai pieni ravinteikkaus indikoi usein harvinaista lajistoa.

Yleisimmin käytetyillä kaukokartoitusaineistoilla ei pystytä suoraan havaitsemaan metsämaan ravinteikkuutta. On toki olemassa erityissensoreita, joilla tämä on mahdollista: esimerkiksi kallioperässä luontaisesti syntyvän gammasäteilyn mittauksien on havaittu olevan yhteydessä puuston kasvuun erityisesti karuilla kasvupaikoilla, sillä maaperän kosteus ja maalaji vaikuttavat gammasäteilyn voimakkuuteen (Mohamedou ym. 2014). Kuitenkin suuraluetulkinnassa kasvupaikan ominaisuudet on yleensä pääteltävä kasvillisuuden perusteella.

Puulaji voi osaltaan kertoa kasvupaikkatyypistä, sillä esimerkiksi suuri lehtipuiden määrä voi indikoida rehevää kasvupaikkaa. Toisaalta esimerkiksi lehdon erottaminen lehtomaisesta kankaasta vaatisi metsän pohja-, kenttä- ja pensaskerrostien kasvillisuuden suoraa havainnointia. Kaukokartoituksen näkökulmasta tämä on ongelmallista, sillä puiden latvukset estävät näkyvyyttä metsän pohjalle. Laserkeilaimen lähettämät pulssit pystyvät osin tunkeutumaan latvuston läpi pienistäkin aukoista, mikä mahdollistaa maanpinnan korkeuden mittaamisen. Kasvillisuuden ominaisuuksien kuvaamisessa tärkeät intensiteettiarvot jäävät kuitenkin epäluotettaviksi, sillä vaikeasti mitattava osa laserpulssein tehosta jää yleensä jo ylimpään latvuserrokseen (Korpela ym. 2012).

Avoimissa metsissä aluskasvillisuutta voidaan kuitenkin havaita suoraan latvusaukkojen kautta. Esimerkiksi jäkäläköt on mahdollista tunnistaa laserkeilauksen intensiteetteihin (Korpela 2008) tai hyperspektrikuviin (Kuusinen ym. 2023) perustuen, mikä voisi helpottaa karujen kasvupaikkojen tunnistamista. Kasvupaikkatyypin suora mallinnus on kuitenkin haastavaa, erityisesti jos kasvupaikkatyyppejä ennustetaan pelkästään aluskasvillisuuden ominaisuuksien perusteella. Hokkanen (2023) hyödynsi tämäntyyppisessä tutkimuksessaan normaalia tarkempaa monikanava-laserkeilausaineistoa, mutta pääsi vain 59 % kokonaistarkkuuteen, vaikka ongelmaa oli yksinkertaistettu yhdistämällä kuivat ja kuivahkot kankaat sekä lehdot ja lehtomaiset kankaat.

Koska alikasvoksen ja pohjakasvillisuuden suora tulkinta ja linkittäminen kasvupaikan ominaisuuksiin on vaikeaa, myös kasvupaikkatyyppejä ennustetaan yleensä niin, että selittäviissä piirteissä on mukana myös puustoa kuvaavia piirteitä. Hokkasen (2023) tutkimuksessa kasvupaikkaluokituksen tarkkuus parani 59 %:sta 68 %:iin, kun mukaan otettiin pohja- ja alikasvosta kuvaavien piirteiden lisäksi myös puuston ominaisuuksia sisältäviä laserkeilaus- ja satelliittikuvapiirteitä. Pippuri ym. (2016) pääsivät vastaavassa tutkimuksessaan talousmetsissä 69 % tarkkuuteen, ja totesivat että satelliittikuvilta lasketut spektri- ja rakennepiirteet olivat laserkeilattuja rakennepiirteitä luotettavampia kasvupaikan indikaattoreita. Vehmas ym. (2011a) luokittelivat suojelualueella sijaitsevia kuvioita viiteen kasvupaikkatyypin lentolaserkeilauksen geometria- ja intensiteetti- ja tiheyspiirteiden avulla, mutta luokittelun tarkkuus jäi 58 %:n. Näiden tulosten perusteella laserkeilaukseen tai satelliittikuviin perustuvien kasvupaikkatietojen tarkkuus ei riitä arvokkaiden elinympäristöjen tulkintaan.

On myös mahdollista laatia malleja esimerkiksi lehtojen suoraan erotteluun muista kasvupaikoista. Tätä lähestymistapaa tutkivat Vehmas ym. (2009) hyödyntäen kuviotason tutkimusaineistoa Kolin kansallispuistosta. Työssä hyödynnettiin vain lentolaserkeilausaineistoa, josta laskettiin korkeus- ja tiheyspiirteitä. Tulosten mukaan 65 % lehdosta luokiteltiin oikein. Lukema on suhteellisen alhainen, kun otetaan huomioon, että työssä oli vain kaksi kasvupaikkaluokkaa. Toisaalta aineistona hyödynnettiin vain lentolaserkeilausta ja sen peruspiirteitä, ei esimerkiksi intensiteettiä tai muita tietolähteitä. Lisäksi työ tehtiin kuviotasolla, jolloin voidaan olettaa, että kuvioiden sisäinen vaihtelu oli suurta. Tarkkuus olisi voinut parantua, jos mikrokuviointi olisi ollut pienipiirteisempi, tai jos käytössä olisi ollut nykyaikaisempia kaukokartoitusaineistoja. Toisaalta tutkimusalue sijaitsi poikkeuksellisen rehevällä alueella Kolin kansallispuistossa. Menetelmän laaja-alainen soveltaminen talousmetsissä, joissa lehtoja on vähän, olisi huomattavasti haastavampaa.



Paahdeympäristöt ovat nimensä mukaisesti kohteita, joita luonnehtivat voimakas auringon säteily, korkea päivälämpötila, jyrkät lämpötilavaihtelut ja niukkaravinteisuus. Puustoisia paahdeympäristöjä ovat esimerkiksi jotkin dyynit ja harjut; yleisimmin ne siis ovat kuivilla hiekka- tai kalliomailla ja mäntyvaltaisilla. Luonnonolosuhteissa edellä kuvailtuja rakennepiirteitä ylläpitävät toistuvat metsäpalot, ja paahdeympäristöjen eliöyhteisöt ovatkin evolutiivisesti sopeutuneet usein toistuviin kuluihin. Paahdeympäristöjen kaukokartoituksen pitäisi olla mahdollista perustuen maanpinnan korkeusmalleista saatavaan topografiatietoon ja kosteusindekseihin, mäntyvaltaiseen puustoon sekä karuun pintakasvillisuuteen, mutta aihetta ei ole toistaiseksi tutkittu.

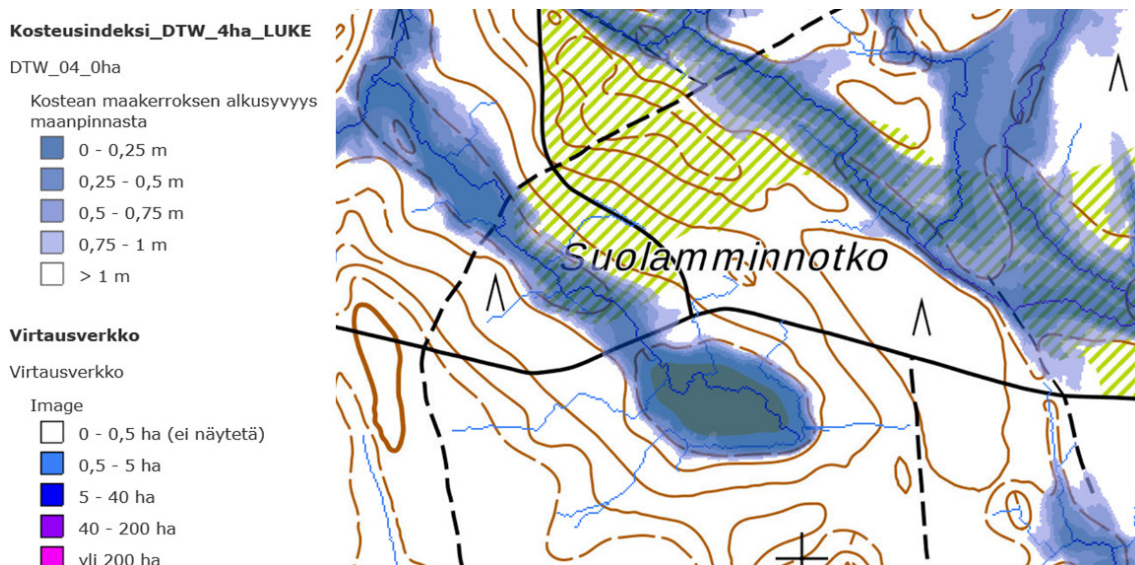
Vanhoja tai luonnontilaisen kaltaisia metsiä on myös pyritty tunnistamaan kaukokartoitusaineistoista. Tunnistaminen ei kuitenkaan ole suoraan perustunut puuston ikään, jonka määrittäminen laserkeilauksella on haastavaa (Maltamo ym. 2020; Schumacher ym. 2020), vaan talousmetsistä poikkeavaan puuston rakenteeseen. Sverdrup-Thygeson ym. (2016) luokittelivat erityyppisiin metsiin sijoitettuja koaloja talous- ja luonnontilaisen kaltaisiin metsiin lentolaserkeilausta käyttäen. Kaakkois-Norjassa sijainneiden metsien luonnontilaisuutta arvioitiin metsien käsittelyhistorian avulla. Luokituksessa käytettiin laserkeilauksen aluepohjaista menetelmää, jossa selittäjinä oli myös yksinpuintulkinnasta johdettuja piirteitä. Erityisesti latvuston vaakasuuntaista rakennetta kuvaavat piirteet olivat malleissa hyödyllisiä: luonnontilaisuutta indikoivat mm. suhteessa pienempi tunnistettujen latvojen määrä, suuri vaihtelu latvusten säteissä, latvusaukkojen suuri koko ja alhainen määrä sekä suuri vaihtelu latvuskäikujen korkeuksissa. Luokituksen tarkkuus oli 89–91 %, mitä voidaan pitää hyvänä. Yhdellä tutkimusalueella saatuja tuloksia ei kuitenkaan välttämättä voida yleistää muille alueille.

Huo ym. (2023) arvioivat Ruotsissa metsiköiden luonnontilaisuutta maastossa 80-koh- taisen kyselylomakkeen perusteella. Tämän jälkeen samoilta kohteilta tunnistettiin erittäin tiheän (50 pulssia m<sup>-2</sup>) lentolaserkeilausaineiston avulla maa- ja pystylahopuut sekä latvusläpimitaltaan poikkeuksellisen suuret elävät puut, joiden oletettiin olevan joko suurikokoisia lehtipuita tai poikkeuksellisen iäkkäitä havupuita. Tunnistettujen puiden yhteenlaskettu lukumäärä korreloi positiivisesti maastossa arvioidun luonnontilaisuuspisteytyksen kanssa ( $R^2=0.60$ ), eli menetelmä vaikuttaa lupaavalta suojeluarvoltaan merkittävien metsiköiden tunnistamiseen.

Suomessa Vehmas ym. (2011b) vertailivat luonnontilaisten ja talousmetsien latvusaukkojen ominaisuuksia. Lähtökohtaisesti luonnontilaisten metsien latvusaukot johtuvat kaatuneista puista, kun taas talousmetsissä aukot ovat useimmiten harvennusten aikaansaamia. Tutkimuksessa latvusaukkojen kohdilta laserkeilauksella mitatuista metsän pohjan korkeusominaisuuksista ja intensiteeteistä havaittuja eroja hyödynnettiin luonnon- ja talousmetsien erottelussa. Maastotyöhön verrattuna lentolaserkeilauspohjainen latvusaukkojen analysointi on huomattavasti nopeampaa, mutta on ongelmallista, että latvusaukoksi tulkittavan kohteen koolle tai muodolle ei ole yksiselitteistä määritelmää. Tulosten hyödyntäminen luonnonmetsien tunnistamiseen suojelualueiden ulkopuolella vaatisi lisätutkimusta, jota Suomessa ei tiettävästi ole tehty. Lähestymistapa voi siksi sopia paremmin pienaukkodynamiikan tutkimiseen tietyllä alueella kuin eri alueiden luokitteluun luonnon- tai talousmetsiksi.

### 3.6 Pienvedet ja vesistöjen suojavyöhykkeet

Luonnontilaiset tai luonnontilaisen kaltaiset purot, norot, lähteet ja pienet lammet ovat metsälain 10 §:ssä suojeltuja kohteita. Hakkuita tehtäessä tällaisten pienvesien ympärille tulee jättää riittävä suojavyöhyke, jotta niille tyypilliset kasvillisuus, pienilmasto ja muut ominaispiirteet säilyvät. Suojavyöhykkeen leveys harkitaan tapauskohtaisesti, mutta lähtökohtaisesti suojavyöhykkeen tulee vastata leveydeltään vähintään valtapuuston pituutta (Metsäkeskus 2022a). PEFC- ja FSC-sertifikaattien mukaan suojavyöhykkeitä tulee jättää kaikkien vesistöjen ja pienvesien ympärille



**Kuva 4.** Peruskartan päällä esitetyt kosteusindeksi- ja virtausverkkokartat. Sininen väri kuvaa kostean maakerroksen syvyyttä. Siniset ja violetit suonet ovat potentiaalisia virtausuomia. Lähde: Suomen metsäkeskus.


mm. kiintoaine- ja ravinnehuuhtoumien välttämiseksi. Suojavyöhykkeen leveydeksi suositellaan usein vähintään 10–15 m.

Ilmakuva- ja laserkeilausaineistojen tulkintaan perustuva topografinen karttatieto on Suomessa tarkkaa ja sisältää jo nykyisin suuren osan suojelluista pienvesistä. Olemassa olevaa tietoa on edelleen mahdollista täydentää kaukokartoitusaineistojen tarkkuuden parantuessa. Ongelmallista voi myös olla pienvesien luonnontilaisuuden tunnistaminen, sillä kartta-aineistot eivät juuri sisällä tietoa pienvesiä ympäröivästä kasvillisuudesta (Tolonen ym. 2019).

Lentolaserkeilausaineistosta laaditut maanpinnan korkeutta kuvaavat pintamallit ovat hyödyllinen työkalu myös veden virtausuomien tulkinnassa (Hilli ym. 2022). Maanmittauslaitos tuottaa tarkkuudeltaan 2 m pintamallin jokaisen laserkeilausprojektin yhteydessä. Pintamallista voidaan edelleen laskea veden valumista kuvaavia kosteusindeksi- ja virtausverkkokarttoja, joiden avulla voidaan tunnistaa myös pieniä ja tilapäisiä valumauomia (kuva 4). Suomen metsäkeskus jakaa näitä karttoja verkkosivuillaan suoraan käyttäjille, sillä niitä voidaan hyödyntää esimerkiksi norojen tunnistamisessa, suojavyöhykkeiden leveyden suunnittelussa ja säästöpuuryhmien sijoittamisessa (Hilli ym. 2022; Metsäkeskus 2022b).

Lentolaserkeilauksen ja ilmakuvien avulla voidaan saada tarkkaa tietoa vesistöjen varrelle jätettyjen puskurivyöhykkeiden leveydestä ja niille jätetyn puuston ominaisuuksista (Goetz 2006; Klemas 2014). Erityisen hyödyllinen työkalu on lentolaserkeilauksella laadittu latvuston korkeusmalli, jonka avulla rantojen ja pienvesien suojavyöhykkeet voidaan tunnistaa ja digitoida automaattisesti samalla tavalla kuin muutkin metsikkökuviot (kuva 5). Ilmakuvatietoa hyödyntämällä myös puulaji voidaan tunnistaa yleisellä tasolla. Tarkempi pienvesien luonnontilaisuuden tulkinta vaatisi kuitenkin droonilaserkeilauksen tasoista erittäin tarkkaa aineistoa, jotta tätä indikoivat ominaispiirteet, kuten virtausuoman vaihteleva muoto, uomaan ja sen ympärille kaatuneet lahpuut sekä monimuotoinen kasvillisuus (Tolonen ym. 2019) saataisiin tulkittua luotettavasti. Kanadalaistutkimuksessa on jo osoitettu, että 3–13 m levyisten pienten jokien uomiin kaatuneet läpimitaltaan >10 cm paksuiset puut voidaan tunnistaa tiheän (25 pulssia m<sup>-2</sup>) lentolaserkeilausaineiston avulla (Dakin Kuiper ym. 2023).

Maanmittauslaitoksen laserkeilausaineistojen hitaahko päivittyminen kuuden vuoden syklillä rajoittaa laserkeilauksen käyttöä hakkuissa jätettävien suojavyöhykkeiden valvonnassa. Tästä



**Kuva 5.** Latvuston korkeusmallista erottuu selvästi hakkuussa järven rantaan jätetty noin 15 m leveä suojavyöhyke. Lähde: Suomen metsäkeskus.

syystä Suomen metsäkeskus hyödyntää hakkuiden kohdennetuissa maastotarkastuksissa myös drooneja. Drooneilla kerätyistä aineistoista saadaan niin ikään lasketuksi ilmakuvamosaiikkeja tai 3D-pistepilviä, joiden avulla metsälakikohteiden ympärille jätettyjen suojavyöhykkeiden leveyttä voidaan arvioida luotettavasti.

### 3.7 Lajien runsaus ja elinympäristöt

Kaukokartoitusta, erityisesti lentolaserkeilausta, on sovellettu runsaasti myös yksittäisille eläin- ja kasvilajeille sopivien elinympäristöjen tunnistamiseen. Ekologisessa tutkimuksessa esimerkiksi latvuston pystysuuntaisen rakenteen monimuotoisuuden on todettu korreloivan lajiston runsauden kanssa, ja sitä on huomattavasti helpompaa mitata laserkeilauksen avulla kuin maastotyönä (Müller ja Vierling 2014). Samoin laserkeilauksella saadaan suoraa tietoa metsän latvuspeittävydestä, joka on esimerkiksi metson (*Tetrao urogallus*) elinympäristöjen kannalta tärkeä piirre (Graf ym. 2009). Lajien monimuotoisuuden kaukokartoitus pohjaisissa mallinuksissa vastemuuttujana on usein jokin lajimäärää kuvaava indeksi: esimerkiksi lajien lukumäärä tietyllä alueella ( $\alpha$ -diversiteetti), lajien keskinäiset runsaudet huomioiva Shannonin indeksi, tai Simpsonin indeksi, joka kuvaa todennäköisyyttä, että kaksi alueelta satunnaisesti tavattua yksilöä kuuluu eri lajiin (Toivonen ym. 2023).

Suomessa kaukokartoitusta on käytetty erityisesti metsälintujen elinolosuhteiden mallinnuksessa. Vihervaara ym. (2015) ja Mononen ym. (2018) havaitsivat, että kansalaishavainnoista koottuja eri lintulajien esiintyvyytietoja voidaan mallintaa laserkeilauspohjaisella metsävaratiedolla. Keskimäärin lintujen havaittiin suosivan tiheitä ja korkeampipuustoisia metsiä, mutta riippuvuudet vaihtelivat eri lajeille. Melin ym. (2016) havaitsivat laserkeilausaineistoon ja riistakolmiolaskentoihin perustuen, että metsäkanalintujen poikueita esiintyi runsaimmin sellaisissa metsissä, joissa oli tiheää aluskasvillisuutta, mutta myös puuston pituudella oli merkitystä. Vauhkonen ja Imponen (2016) totesivat, että laserkeilausaineiston osittain ohjattu luokittelu on lupaava menetelmä metson ja pyyn (*Tetrastes bonasia*) elinympäristöjen huomioimiseksi metsäsuunnittelussa.

Myös Ruotsissa on havaittu lintujen lajirikkauden ja runsauden riippuvan erityisesti alikasvoksen tiheydestä ja puuston pituudesta, jotka voidaan määrittää laserkeilauksella (Lindberg ym. 2015; Klein ym. 2020). Kovakuoriaisten runsaus ja lajirikkaus sen sijaan riippuivat lähinnä

puuston koosta ja puulajisuhteista (Lindberg ym. 2015). Epifyyttijäkälien lajimäärän havaittiin puolestaan kasvavan latvuskerroksen harventuessa, sillä monet ryhmän lajit hyötyvät suuremmasta valon määrästä (Klein ym. 2020). Suomessa on myös havaittu, että laserkeilausaineistoista tulkitut latvuston korkeus, runkoluku ja pääpuulaji selittävät epifyyttijäkälien lajistoa vähintään yhtä hyvin kuin maastossa arvioitujen tunnuksien (Palmroos ym. 2023). Nämä tulokset osoittavat, että lajistolliselle monimuotoisuudelle ei ole yhtä universaalista indikaattoria, vaan parhaiten toimivat indikaattorit riippuvat kyseisen lajiryhmän ja sen lajin biologisista ominaisuuksista.

Kasvi- ja sienilajien lajirikkautta tai yhteisörakenteen vaihtelua kaukokartoituksella mallintavia tutkimuksia ei ole juurikaan tehty Pohjoismaiden boreaalisista metsistä. Kuitenkin Bohlin ym. (2021) osoittivat Ruotsin VMI-aineistoja käyttäen, että valtakunnallisia mustikan (*Vaccinium myrtillus* L.) ja puolukan (*Vaccinium vitis-idaea* L.) satoja voidaan mallintaa lentolaserkeilausaineistosta laskettujen piirteiden, kuten latvuspeittävyuden, avulla. Lisäksi malleissa hyödynnettiin mm. maaperä-, topografia- ja sää tietoja. Tanskassa on myös havaittu laserkeilauksella määritetyn latvuston tiheyden korreloivan pohjikasvilajien ja sammalten esiintymisen kanssa (Alexander ym. 2013; Moeslund ym. 2019). Samoin sienilajien runsauden mallinnus onnistui Saksassa tehdyssä tutkimuksessa paremmin laserkeilausaineistoon kuin maastomittauksiin perustuen (Peura ym. 2016).

Lajimäärää kuvaaviin indekseihin tai yksittäisten lajien tai lajiryhmien elinympäristövaatimuksiin perustuvat mallit eivät välttämättä sovellu suoraan metsien monimuotoisuuden seurantaan, sillä tietynlainen latvuston rakenne ei automaattisesti takaa sitä, että paikalta löytyisi tietty laji tai lajeja. Kaukokartoitukseen perustuvien elinympäristömallien tarkkuudet ovat olleet yleisesti ottaen alhaisia, mutta kuitenkin samaa tasoa kuin mallinnettaessa elinympäristöjä maastomittauksien perusteella (Toivonen ym. 2023). Esimerkiksi lintujen ja kovakuoriaisten osalta on parhaimmillaan päästy 40–60 % selitysasteeseen (Toivonen ym. 2023). Tällaiset mallit soveltuvat vähintään eri lajien potentiaalisten elinympäristöjen paikantamiseen ja maastoinventointien kohdentamiseen. Yleisten potentiaalisia elinympäristöjä kuvaavien karttojen tuottaminen kaukokartoitetun puuston rakenteen perusteella on edullista, mutta varsinaisen lajitason maastotiedon kerääminen on kallista, mikä rajoittaa monien tutkimuksissa esitettyjen menetelmien todentamista.

### 3.8 Oleelliset biodiversiteettimuuttujat eli EBV-piirteet

Ekologisen tiedon perusteella määritellyt monimuotoisuuden eri puolia kuvaavat EBV-luokat jakaantuvat useampiin yksittäisiin piirteisiin (taulukko 1) (GEO BON 2023). Koska EBV-piirteiden tulee mahdollistaa varsin erityyppisten ekosysteemien seuranta, ne ovat luonteelta hyvin yleisiä, eivätkä välttämättä vastaa kansallisesti käytettyjä indikaattoreita (Vihervaara ym. 2017). Ongelmana on myös se, että jotkin piirteet, kuten geneettinen monimuotoisuus, eivät käytännössä ole havaittavissa kaukokartoituksella tai niiden havainnointi on mahdollista vain pienessä mittakaavassa (Skidmore ym. 2021). EBV-piirteiden seurannan tulisi kuitenkin olla toteutettavissa globaalisti, ja tutkimuksessa on siksi keskitytty ennen kaikkea satelliittikaukokartoituksen käyttöön. Myös lentolaserkeilausta on ehdotettu käytettäväksi niillä alueilla, joilla tätä aineistoa on saatavilla (Valbuena ym. 2020).

EBV-luokista parhaiten kaukokartoituksella seurattaviksi soveltuvat ekosysteemien rakenne sekä niiden toiminta ja prosessit, joihin liittyviä kaukokartoitustuotteita on jo saatavilla (Skidmore ym. 2021). Esimerkiksi EBV-luokkaan ekosysteemien rakenne kuuluu kolme yleistä ekosysteemejä kuvaavaa piirrettä: peittävyys, vertikaalinen rakenne ja jakauma. Täsmälliset tunnuksien, joilla näitä piirteitä kuvataan, on määriteltävä erikseen eri ekosysteemeille. Skidmore ym. (2021) ovat hahmotelleet, miten eri EBV-luokat ja -piirteet voitaisiin liittää kaukokartoituksella havaittaviin tunnuksiin (taulukko 1). Boreaalisissa metsissä ekosysteemien rakennetta voitaisiin kuvata esimerkiksi puuston pituusvaihtelua, pirstoutumista ja lahoppuun määrää kuvaavien karttojen avulla.

**Taulukko 1.** Poimintoja kaukokartoituksen kannalta relevanteista EBV-luokista, -piirteistä ja niihin liittyvistä kaukokartoituksella havaittavista tunnuksista (Skidmore ym. 2021).

EBV-luokka	Lajit ja populaatiot	Lajien ominaispiirteet	Eliöyhteisöjen rakenne	Ekosysteemien toiminta ja prosessit	Ekosysteemien rakenne	
EBV-piirre	Runsas Jakauma	Fenologia	Runsas	Fenologia	Ekosysteemien jakauma	
		Morfologia	Taksonominen diversiteetti	Perustuotanto	Ekosysteemien peittävyys	
		Fysiologia	Ominaispiirteiden diversiteetti	Häiriöt	Ekosysteemien vertikaalinen profiili	
		Liikkuvuus	Vuorovaikutusten diversiteetti			
Kaukokartoitettu tunnus	Lajirikkauden indeksit	Kasvukauden alku ja loppu	Eliöyhteisöjen määrä	Hiilen sidonta	Rakenteellinen vaihtelu	
	Lajien läsnäolo alueella	Perustuotanto	Yhdessä esiintyvien lajien määrä	Lehtialaindeksi	Kasvillisuuden korkeus	
		Lehtiala			Haihdunta	Maanpeite
		Klorofyllit			Maaperän kosteus	Pirstoutuminen
					Metsätuhojen pinta-ala	Lahopuu
					Biomassa	

Osa kaukokartoituksella saatavista piirteistä voi toisaalta kuulua useampaan eri EBV-luokkaan: esimerkiksi kasvillisuuden fenologiaa eli vuodenaikaisvaihtelua voidaan seurata sekä laji- että ekosysteemitasoilla.

EBV-luokkien sisältöjen sekä niiden kaukokartoituspohjaisten ja muiden seurantatapojen määrittäminen eri ekosysteemeille ovat tällä hetkellä kesken. Esimerkiksi Valbuena ym. (2020) ehdottivat erityisesti 3D-kaukokartoituksen pohjalta kolmea piirrettä, jotka soveltuisivat yleisesti kuvaamaan metsäekosysteemien rakennetta: puuston korkeus, peittävyys ja vertikaalinen rakenne. Kaukokartoitus ei kuitenkaan ole korvaamassa nykyisiä monimuotoisuuden seurantaan liittyviä maastomittauksia. Pikemminkin maastotyön määrä voi jatkossa lisääntyä, sillä kaikille EBV-piirteille ei ole valmista seurantajärjestelmää, eikä niitä voida kaukokartoittaa riittävän luotettavasti (Vihervaara ym. 2019).

Suomessa EBV-seurantojen kehittämisestä vastaa Suomen ympäristökeskus (Syke). Syke koordinoi myös Suomen ekosysteemiobservatoriota, jonka tavoitteena on kerätä yhteen monimuotoisuuden seurantaan käytettävien indikaattorien tuottamisessa tarvittavia aineistoja, prosesseja ja malleja (Vihervaara ym. 2019).

## 4 Metsäkonetieto ja sen rikastaminen sensoritiedolla

### 4.1 Operatiivisessa toiminnassa kerättävän tiedon mahdollisuudet

Metsissämme operoi päivittäin noin 2000 hakkuukonetta ja 2000 kuormatraktoria, jotka mahdollistavat talousmetsiemme rakenteen ja tilan yksityiskohtaisen mittaamisen ja seurannan suhteessa monimuotoisuusindikaattoreille asetettuihin tavoitteisiin. Tässä luvussa analysoidaan ja raportoidaan viimeisimpään tutkimustietoon sekä asiantuntijanäkemyksiin perustuen metsäkonetiedon käyttömahdollisuuksia, pullonkauloja ja haasteita metsäluonnon monimuotoisuusindikaattoreiden mittaamisessa ja seurannassa puunkorjuun yhteydessä. Näihin indikaattoreihin kuuluvat mm. säästöpuuryhmät, arvokkaat suuret lehtipuut (erityisesti haapa) ja vanhat puut, laho maa- ja pysty-



puu, tekopötkelöt sekä vesistöjen ja pienvesien suojavyöhykkeiden leveydet. Lisäksi luvussa 5 hahmotellaan tiekarttaa metsäkonetiedon hyödyntämismahdollisuuksista metsäluonnon monimuotoisuuden dokumentoinnissa lähivuosina (2023–2025) ja 2020-luvun loppupuolella (2026–2029).

Perinteisen metsäkonetiedon (mm. StanForD 2010 -metsäkonestandardin mukaiset tuotantotiedostot; Skogforsk 2021) lisäksi tulevana vuosina metsäkoneisiin integroidut laserkeilaukseen tai/ ja konenäköön perustuvat sensorijärjestelmät voivat mahdollistaa uudenlaisen, monipuolisemman metsäluonnon rakenteellisen monimuotoisuuden kartoittamisen hakkuiden yhteydessä. Tämä mahdollistaa metsäkoneenkuljettajaa avustavien järjestelmien kehittämisen sekä energia- ja resurssitehokkaan, ilmastokestävän ja metsäluonnon monimuotoisuutta lisäävän puunkorjuun (Kärhä ym. 2021, 2023).

## 4.2 Hakkuukoneen ja hakkuulaitteen paikannus ja sijaintitiedon potentiaali

Metsäkoneiden StanForD 2010 -tiedonsiirtostandardin mukaisesti hakkuukoneet määrittävät GNSS (Global Navigation Satellite System) -mittalaitteella hakkuukoneen sijainnin puuta kaadettaessa. Kaadon jälkeen puu prosessoidaan hakkuulaitteella, jolloin kaadetun puun puulaji-, läpimitta-, pituus-, tilavuus-, puutavaralaji- sekä sijaintitieto tallentuvat hpr (harvested production) -tiedostoon. Hakkuukoneen sijaintitieto yhdistettynä kaadetun puun mittaustietoihin ja muihin avoimiin tietolähteisiin tarjoaa mielenkiintoisia mahdollisuuksia luonnonhoidon ja metsäluonnon monimuotoisuuden seurantaan ja todentamiseen.

Puuta prosessoitaessa on myös mahdollista tallentaa lisätieto kaadetusta puusta, mikä auttaa toimijoita metsäluonnon monimuotoisuuden hallinnassa. Hyödynnettäessä runkokoodia (StemCode) hakkuukoneen kuljettaja kirjaa runkokoodin kaadetulle puulle. Koodi kirjautuu edelleen hpr-tiedostoon käsitellylle puulle. Runkokoodien avulla hakkuukoneen kuljettaja voi merkitä esimerkiksi tekopötkelön teon. Huomattavaa on, että jos tekopötkelön latvasta ei tehdä yhtään korjattavaa pötkkyä, runkokoodia ei voida käyttää. Runkokoodin käyttö edellyttää siis, että prosessoitavasta rungosta tehdään vähintään yksi pötkky, esimerkiksi kuitupuupötkky. Hakkuukoneenkuljettaja voi merkitä myös jätettävän säästöpuuryhmän ja kirjata runkokoodilla säästöpuuryhmän ympäriltä hakattavat rungot. Niin ikään kuljettaja voi merkitä runkokoodia painamalla muun käsittelemättömän alueen, esimerkiksi vesistön ja pienvesien suojavyöhykkeen, avainbiotoopin, suojeltavan alueen tai riistatiheikön, sekä kirjata runkokoodilla kyseisen alueen ympäriltä hakatut puut. Vastaavasti runkokoodilla voidaan kertoa, että kyseinen hakattu puu on kaadettu suojeltavalta alueelta, esimerkiksi vesistön tai pienveden suojavyöhykkeeltä, säästöpuuryhmästä, suojeltavalta tai muuten käsittelemättä jätettävältä alueelta. Runkokoodien hyödyntäminen metsäluonnon monimuotoisuuden dokumentoinnissa ja hallinnassa on ollut Suomessa suhteellisen vähäistä. Ruotsissa runkokoodien käyttö on huomattavasti aktiivisempaa kuin Suomessa.

Suomessa toimijat lähettävät hakkuilta metsäomistajan luvalla työmaan kuviogeometrian, toteutusajan sekä käsittelymenetelmän (esim. harvennushakkuu, päätehakkuu) Suomen metsäkeskuksen Kaato-palveluun (Triona 2020). Kaato-palvelussa Suomen metsäkeskus päivittää käsittelykuviot hakkuukonekuvioinnin perusteella avoimeen metsään.fi -metsävaratietoon (Melkas ym. 2020). Hakkuukonekuvioinnissa käytetään hpr-tiedostoista poimittua hakkuukoneen sijaintitietoa, joka kirjautuu kullekin hakatulle puulle siltä työpisteeltä, missä hakkuukone on sijainnut puuta käsiteltäessä (Melkas ym. 2020). Hakkuukonekuvioinnin perusteella voidaan määrittää alueet, missä puunkorjuuoperaatiot on tehty, ja päivittää ne metsävaratietoon. Yhdistämällä hakkuukonekuviointi muihin paikkatietoaineistoihin voidaan todentaa luontokohteiden säästäminen puunkorjuuoperaatioiden yhteydessä (Seppälä ym. 2021). Menetelmä on automatisoitavissa, ja pilottisovellus on ollut käytettävissä Metsäteho Oy:ssä vuoden 2023 alusta alkaen. Käytettävissä olevia luontokohteiden paikkatietoaineistoja ovat:

- Suomen metsäkeskuksen metsälain 10 § kohteet sekä muut arvokkaat elinympäristöt.
- METSO-ohjelmaan kuuluvat alueet (osana Kemera-aineistoja).
- Natura 2000 -alueet ja muut luonnonsuojelualueet.
- Uhanalaisten lajien havaintotiedot.
- Muinaisjäännöskohteet.

Hakkuukonekuviointissa kuvioiden sisälle syntyy usein käsittelemättömiä alueita, joita ei voida tunnistaa luontokohteiden paikkatiedoista. Näistä osa on potentiaalisia, tunnistamattomia luontokohteita, joiden luonteesta voidaan saada viitteitä maastotietokannasta (esimerkiksi jyrkän-teet, kalliot) tai kosteusindeksikartoista (terrain wetness index (TWI), depth to water (DTW)). Käsittelemättömyyden syynä voi olla myös säästöpuuryhmän jättäminen. Näiden kohteiden tunnistuksen varmennus edellyttää joko kuljettajan tekemää merkintää hakkuukoneen tietojärjestelmään tai jälkikäteistodentamista kartoilta joko toimisto- tai maastotyönä (vrt. Seppälä 2021).

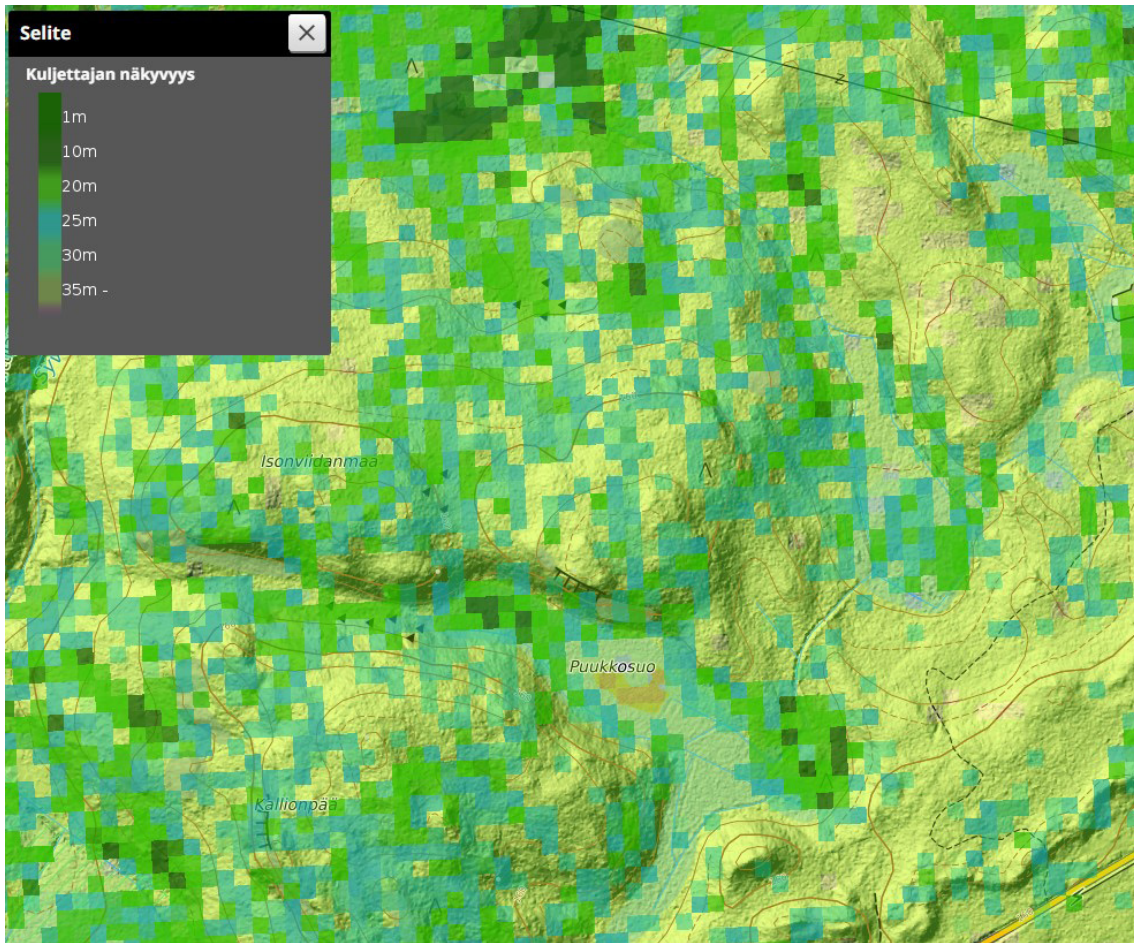
Hakkuukoneen sijainnin lisäksi myös hakkuulaitteen tarkka sijainti suhteessa hakkuukoneeseen on mahdollista paikallistaa, mikäli hakkuukoneen puomi on anturoitu. Puomin anturointi on alkanut yleistyä hakkuukoneissa kärkiohjauksen (eli puomin pään tietokoneavusteinen ohjaus: John Deere Intelligence Boom Control (IBC); Komatsu Smart Crane; Ponsse Active Crane) myötä. Poistumakuviointissa hyödynnetään hakkuukoneen hakkuulaitteen sijaintitietoa, joka on kirjautunut kullekin hakatulle puulle. Poistumakuviointi tuottaa tarkempaa sijaintitietoa hakattujen käsittelykuvioiden aluerajoista kuin hakkuukonekuviointi, ja kykenee erottamaan kuviorajat ja käsittelemättömät kohdat täsmällisemmin (Riecki ja Malinen 2022a). Hakkuulaitteen sijaintitietoa voidaan käyttää myös vesistöjen ja pienvesien suojavyöhykkeiden leveyden määrittämisessä (Riecki ja Malinen 2022b; Haavisto 2023).

Ilman erillisiä sensoreita hakkuukoneet eivät kuitenkaan pysty mittaamaan jäävää puustoa. Hpr-tiedostojen poistuma- ja sijaintitietoa on kuitenkin mahdollista käyttää ensiharvennuksilla jäävän puuston määrän ja tiheyden arviointiin. Menetelmässä verrataan ajouralta poistettujen puiden hakkuukertymää ajourien väliseltä alueelta hakattuun poistumaan. Tällöin ajouralinjalta poistettu puusto antaa viitteen puunkorjuutyömaalle jäävästä puustosta (Hannrup ym. 2011). Hpr-poistumatietoa voidaan verrata myös puunkorjuuta edeltävään, olemassa olevaan metsävaratietoon. Menetelmän käytettävyyys paransi merkittävästi, mikäli metsävaratietoa olisi tarjolla yksittäisten puiden tarkkuudella (Hyypä ja Inkinen 1999).


Teknologia mahdollistaa jo tällä hetkellä hakkuukoneen paikannukseen perustuvien sovel-lusten laajamittaisen käytön. Esimerkiksi Risutec Oy tarjoaa koneyrityksille ASTA-ex-palvelua. Risutec ASTA-ex on työkoneen – esimerkiksi hakkuukoneen – puomiin asennettu merkintä- ja ohjauslaite, joka tarjoaa valmistajan mukaan senttimetrin sijaintitiedon tarkkuuden (Risutec 2021). Yksi mahdollisuus metsäluonnon monimuotoisuuden huomioimiseen hakkuissa on myös käyttää konevalmistajien tarjoamia karttatuotteita esimerkiksi riistatiheiköiden sijoittamisessa (kuva 6).

Hakkuulaitteen paikannus yleistyy nopeasti, ja Komatsu-hakkuukoneet tallettavat jo automaattisesti hakkuulaitteen sijaintitietoa. Metsäkoneissa, joissa puomia ei ole anturoitu, hakkuu-laitteen sijaintitieto voidaan määrittää puomin vakiomitan (esim. 8 m; Melkas ja Riecki 2017) perusteella ja poistettavan puun suunta suhteessa hakkuukoneeseen perustuen ohjaamon suunnan anturointiin (kuva 7).

Taipaleen ym. (2022) tutkimuksessa hakkuulaitteen sijaintitarkkuus oli 5,2 metriä, mikäli käytettiin hpr-tiedostoon tallennettua vakiopuomin mittaa. Metsätehon laskenta-algoritmeilla parannettu sijaintitarkkuus oli 4,2 metriä, ja mikäli myös puomin anturointi otettiin huomioon, sijaintitarkkuudessa päästiin 3,9 metriin. Hakkuulaitteen sijainti suhteessa hakkuukoneeseen on anturoinnin ansiosta varsin tarkkaa, ja sijaintivirhe koostuukin lähes kokonaan hakkuukoneen paikannusvirheestä. Paikannusteknologia (GNSS) kehittyy kovaa vauhtia, ja metsäkonevalmistajat ovat tuomassa markkinoille lähitulevaisuudessa aiempaa merkittävästi tarkempia GNSS-laitteita.



**Kuva 6.** Hakkuukoneenkuljettaja voi käyttää riistatiheiköiden suunnittelussa ja sijoittamisessa konevalmistajan tarjoamia karttatasoja. Kuvassa John Deere TimberMatic Kartat -karttatasojen tarjoama Näkyvyyskartta. Esimerkkikuvassa Puukkosuon sekä länsi- että itäosassa näyttäisi olevan potentiaalisia (eli huono näkyvyys kuljettajalle) paikkoja riistatiheiköille. Lähde: John Deere Forestry Oy.



**Kuva 7.** Kuvaus hakkuulaitteen geometrian laskennasta Komatsu-hakkuukoneella (Melkas ja Rieki 2017).




### 4.3 Hakkuukoneella kerättävä sensoritieto

Ponsse Oyj julkisti FinnMETKO 2022 -messuilla hakkuukoneeseen integroidun mobiililaserkeilaus- ja harvennusavustin-tuotekonseptin. Konseptissa hakkuukoneessa oleva Ouster-laserkeilain (ouster.com) skannaa metsää ja osoittaa hakkuukoneenkuljettajalle lähimaastossa olevat puut sekä jo käsitellystä metsästä hakattujen ja jäävien puiden sijainnit hakkuukoneen kuljettajalle (kuva 8).

Metsäkoneisiin integroituja sensoreita (esim. laserkeilain, kamera) ei ole tutkittu vielä normaalin hakkuutyön yhteydessä tehtävässä monimuotoisuusindikaattoreiden dokumentoinnissa ja mittaamisessa. Maa- ja metsätalousministeriön rahoittamassa ja Paikkatietokeskuksen, Itä-Suomen yliopiston, Luken ja Ponsseen toteuttamassa Kohti ilmastokestävämpää ja monimuotoisempaa puunkorjuuta sensoriteknologian ja tarkan paikkatiedon avulla (IlmoStar) -hankkeessa demonstroidaan vuosina 2023–2025 tulevaisuuden hakkuukoneen suorituskykyä metsäluonnon monimuotoisuuden mittaamisessa ja seurannassa. Hankkeessa tutkitaan esimerkiksi menetelmiä säästöpuuryhmien ja suurten lehtipuiden tehokkaampaan säilyttämiseen hakkuissa tarkemmalla ajourien sijoittamisella ja suuntaamisella, sekä uuden sensoriteknologian hyödyntämistä hakkuukoneavusteisessa puulajitunnistuksessa (esim. lehtipuun osuus), elinvoimaisimpien puiden tunnistamisessa (esim. elävän latvuksen osuuden määrittäminen), tekopökkelöiden havainnoinnissa ja sijoittamisessa, lahopuiden havainnoinnissa ja niiden tilavuuden laskennassa ja optimoinnissa, sekä riistametsänhoitoa vaativien tiheikköjen optimoinnissa.

Hakkuukoneeseen liitetyn laserkeilausmahdollisuuksia puukarttojen tuottamisessa on tutkittu esimerkiksi Metsätehon ja Turun yliopiston yhteishankkeessa (Nevalainen ym. 2020) sekä UNITE-lippulaivan järjestämissä Luken, Paikkatietokeskuksen ja Itä-Suomen yliopiston yhteis-



**Kuva 8.** Reaaliaikainen näkymä hakkuukoneenkuljettajalle Ponsse-harvennusavustin-tuotekonseptissa: a) harmaan eri sävyillä ajourat ja puomin ulottuma ja väliin jäävä musta alue edustaa aluetta, johon puomilla ei ole voinut yltää, b) ajouravälin osoitin (23,5 m), c) kaadetut puut (eli kannon paikat) harmaina pisteinä, d) pystyssä olevat/pystyytyn jääneet puut vihreinä pisteinä ja e) tihentymät punaisella. Lähde: Ponsse Oyj.

tutkimuksissa metsäkoneen sijainnin paikantamiseksi vuosina 2021 ja 2022. Näihin tutkimuksiin Paikkatietokeskus on tuonut kaksi erityyppistä laserkeilainratkaisua: toinen on samankaltainen Ponssen harvennusavustimen kanssa ja toinen perustuu pyörivään laserkeilaimeseen. Menossa olevilla UNITE-tutkimuksilla ja käynnistyvällä IlmoStar-hankkeella pyritään todentamaan, että metsäkoneeseen asennetuilla laserkeilaimilla päästään puuston dimensioiden ja sijainnin mittaamisessa samoihin tarkkuuksiin kuin perinteisillä mobiilikeilainratkaisuilla, joita on testattu tutkimuksissa.

Mobiililaserkeilaimien kykyä mitata puustotunnuksia on aikaisemmin tutkittu siten, että ne on asennettu mönkijään. On myös tutkittu käsi- tai reppulaserkeilaimien ja metsän sisällä lentävän droonin tuottamia pistepilviä. Tehdyissä tutkimuksissa (esim. Liang ym. 2015; Bauwens ym. 2016; Forsman ym. 2016; Kukko ym. 2017; Del Perugia ym. 2019; Hyyppä ym. 2020) mobiililaserkeilaimet on todettu tarkoiksi niin puuston dimensioiden (mm. runkokäyrä, läpimitta, pituus) kuin sijainninkin mittaamisessa. Sijaintimittaukseen vaikuttaa se, millä menetelmällä mobiilikeilaimen paikannusratkaisu on tuotettu. Robotiikan puolella on kehitetty monikanavaisia laserkeilaimia (kuten Ouster). Niitä käyttämällä voi toteuttaa robotiikassa käytettyä SLAM (Simultaneous Localization and Mapping) paikannus- ja kartoitusratkaisua. Yhdistämällä SLAM-tekniikkaa GNSS- ja inertiaratkaisuihin päästään todennäköisesti parhaimpaan mittaustarkkuuteen metsän sisällä.

SLAM-algoritmeilla sovitetaan peräkkäiset keilaukset toisiinsa ja määritetään keilaimen liike peräkkäisten keilausten välillä (Fuentes-Pacheco ym. 2015; Huang 2021). Monimutkaisilla algoritmeilla saadaan näin tuotettua sekä keilaimen suhteellinen paikka metsässä että keilaimen näkemä puustokartta. Mittauksiin jää cm-luokan virhettä SLAM-prosessin jälkeenkin. Erityisesti systemaattinen virhe kasvaa ajan funktiona, kunnes palataan samalle, aikaisemmin keilatulle alueelle missä harvesterin keilain näkee samat puut uudestaan. SLAM-menetelmät ovat usein reaaliaikaisia. Puustotunnusten laskennassa voidaan pienentää SLAM-menetelmien systemaattisia virheitä hyödyntämällä sensorin tallentamaa aikatieta (Hyyppä ym. 2020). Tämä mahdollistaa samasta puusta eri aikoina saatujen pistepilvien sovittamisen tarkasti toisiinsa. Puuston läpimitta voidaan mitata mobiililaserkeilauksella parhaimmillaan muutaman prosentin tarkkuudella (Hyyppä ym. 2020). Samaan tarkkuuteen voidaan päästä myös harvesterimittauksessa, mutta mittaustulos on riippuvainen käytetyn laserkeilaimen ominaisuuksista.

## 5 Tutkimustarpeita ja suosituksia käytännön toimenpiteiksi

### 5.1 Kaukokartoitus

Tällä hetkellä käytettävissä olevilla laserkeilaus- ja ilmakehän kuva-aineistoilla saadaan jo varsin luotettavaa laajan mittakaavan tietoa suurten elävien säästöpuiden koosta ja sijainneista, metsien rakenteellisesta monimuotoisuudesta sekä vesistöjen ja tunnistettujen avainbiotooppien suojavyöhykkeistä. Näitä tietoja ollaan jo viemässä Suomen metsäkeskuksen tietojärjestelmiin laajempaa käyttöä varten. Tutkimuksessa voitaisiin näiden tunnusten osalta keskittyä jatkossa siihen, miten kaukokartoituksen tuottamaa paikkatietoa voitaisiin hyödyntää laaja-alaisesti metsien ekologisissa analyyseissä, esimerkiksi elinympäristöjen kytkeytyneisyyden näkökulmasta.

Muut yllä käsitellyt indikaattorit ovat käytännön sovellusten kannalta haastavampia. Vaikka tutkimuksessa on esitetty esimerkiksi lahoppuun ja haavan tunnistamisesta tarkkojakin tuloksia, on syytä huomioda tarkastelujen mittakaava. Esimerkiksi drooneilla, hyperspektrikameroilla ja erittäin tiheillä laserkeilausaineistoilla on saatu hyviä tuloksia useiden monimuotoisuusindikaattorien osalta, kun tutkimuksia on tehty pienehköillä ja tarkkaan rajatuilla alueilla. Tilanne on kuitenkin toinen, jos tavoitteena on analysoida metsien monimuotoisuutta suurilla alueilla. Se, milloin pienalueilla



tutkimuksissa käytettyjä aineistoja on saatavilla suuressa mittakaavassa, riippuu sekä tekniikan kehityksestä että käytettävissä olevista resursseista. Myös sovellustilanne on suuralueilla erilainen kuin esimerkiksi luonnonsuojelualueella, sillä suurin osa alueesta on yleensä talousmetsää, missä monimuotoisuutta merkittävästi ylläpitäviä kohteita on harvassa. Erityisesti jos näiden kohteiden tunnistamiseen käytetään tilastollisia menetelmiä, jotka yleensä keskiarvoistavat alueella esiintyvää vaihtelua, käy helposti niin, että monimuotoisuusindikaattoreita ennustetaan joko liikaa tai ei ollenkaan. Suuralueiden kaukokartoituksessa sovellettavilla menetelmillä tulisi siksi olla vahva fyysikaalinen pohja, että harvinaisten kohteiden tunnistaminen onnistuisi.

Suuraluetulkinnan kannalta haastaviin indikaattoreihin kuuluvat mm. maa- ja pystylahopuun määrä ja laatu, harvinaiset lehtipuut, lehdot ja muut poikkeavat kasvupaikat, sekä pienvesien luonnontilaisuus. Näiden luotettavaa tunnistamista rajoittavat sekä nykyisten kaukokartoitusaineistojen tarkkuus että puute mallinnuksen tueksi tarvittavista maastoaineistoista. Suurikokoisen maa- ja pystylahopuun määrän suora kartoitus yksinpuintulkinnalla voi tulla jatkossa mahdolliseksi, jos lentolaserkeilauksen pulssitiheyttä nostetaan vähintään 15–20 pulssiin neliömetrillä. Tutkimusjulkaisuissa tämä tiheys on riittänyt suurikokoisten maa- ja pystylahopuiden suoraan tunnistamiseen (katso edellä). Menetelmien soveltamista talousmetsissä, missä lahoppuuta on yleensä suhteellisen vähän, pitäisi kuitenkin tutkia lisää. Lisäksi inventointialueilla tulisi tehdä riittävästi lahoppuuston maastomittauksia tukiaineistojen saamiseksi. Tällä hetkellä Suomen metsäkeskuksen inventointikoealojen maastotyöohje edellyttää koealan siirtämistä toiseen paikkaan, jos aiotussa paikassa on enemmän kuin vähäinen määrä kuollutta puuta. Tällä tavoin maksimoidaan puustotietojen tarkkuutta talousmetsissä, joissa lahoppuun määrä on yleensä vähäinen, mutta menetetään mahdollisuus saada tietoa lahoppuun määrästä. Nykytilanteessa tämä on ymmärrettävää, sillä lahoppuun tulkintaan riittävän tarkkoja aineistoja ei ole vielä laajasti käytössä, mutta monimuotoisuustiedon kasvavan tärkeyden ja aineistojen parantuvan laadun takia jatkossa olisi tärkeää parantaa myös maastomitatun lahoppuutiedon saatavuutta. Lahoppuun laadun eli mm. puulajin ja lahoasteen tulkinta säilyy silti todennäköisesti ongelmana suuraluetulkinnossa vielä pitkään.

Haavan ja muiden vähälukuisten lehtipuujen luotettava tunnistaminen laserkeilausinventointien yhteydessä vaatisi koealojen tarkoituksellista sijoittamista alueille, joilla näitä puulajeja esiintyy, jotta tarkempien puulajikohtaisten tulkintamallien laatimiseen olisi käytettävissä riittävästi aineistoa. Lisäksi kaukokartoitusaineistojen laadun olisi parannuttava nykyisestä, että näille puulajeille tyypillisiin rakennepiirteisiin päästäisiin kiinni. Haavan ja koivun vuodenaikaisvaihtelut poikkeavat toisistaan, ja tiheästi toistuvilla mittauksilla tätä voitaisiin mahdollisesti hyödyntää haavan tunnistamisessa. Käytännössä vuodenaikaisvaihtelun seuranta lienee mahdollista suuralueilla vain satelliittikuvien avulla.

Lehtojen ja muiden harvinaisten elinympäristöjen tunnistaminen vaatisi huomattavasti nykyistä tarkempia aineistoja, koska pelkkä puuston rakenteen analysointi ei yleensä tuota niistä riittävän tarkkaa tietoa. Tarvittaisiin aineistoja ja menetelmiä, joilla päästäisiin suoraan käsiksi esimerkiksi aluskasvillisuuden lajimääriin ja muihin pienipiirteisiin yksityiskohtiin, mikä on haastavaa jo pelkästään latvuserroksen aiheuttaman varjostuksen takia. Samalla tavoin ongelmallista on myös pienvesien luonnontilaisuuden tunnistaminen, mikä vaatisi niin ikään erittäin pienipiirteistä tietoa kohteiden topografiasta ja kasvillisuudesta. Käytännössä helpoin tapa parantaa lehtojen tunnistamista voi kuitenkin olla vanhan maastomittauksilla kerätyn tiedon parempi hyödyntäminen.

Jos tavoitteena on tunnistaa suojeluarvoiltaan merkittäviä metsiä, parhaisiin tuloksiin päästään yhdistelemällä useiden eri kaukokartoitettujen indikaattorien tuottamaa tietoa. Harvinaisilla luontotyypeillä voi esiintyä yhtä aikaa esimerkiksi eri-ikäisrakenteisuutta sekä suurikokoisia laho- ja lehtipuita. Maalaji-, valuma-alue- ja kosteusindeksikartoista voi myös olla hyötyä. Mitä useampi indikaattori osoittaa paikan poikkeavaksi, sitä varmemmalla pohjalla tulkinta oletettavasti on (Huo ym. 2023). Tällaiset alueet poikkeavat talousmetsistä usein myös rakenteellisesti, joten

mahdollisuudet kohteiden tunnistamiseen paranevat, jos analyysi ei perustu pelkästään kuvion tai hilasolun sisäiseen rakenteeseen, vaan kohteita arvioidaan myös suhteessa lähiympäristöönsä. Tämän tyyppistä esimerkiksi puuston rakenteen spatiaaliseen autokorrelaatioon (eli lähempänä olevat alueet ovat yleensä luonnostaan samanlaisempia kuin kauempana olevat) perustuvaa tutkimusta ei ole toistaiseksi juuri tehty.

Droonien avulla on mahdollista saada monista yllä mainituista piirteistä tarkempaa paikallista tietoa kuin lentolaserkeilauksella tai ilmakuvilla. Esimerkiksi haavan tunnistaminen droonikuvista on onnistunut pienillä tutkimusalueilla hyvin, kun käytettävissä on ollut mallinnuksen tueksi myös maastomittauksia. Tällä hetkellä droonitulkintoja tukevien maastomittausten kustannukset voivat kuitenkin tulla jo suuremmiksi kuin varsinaisen drooniaineiston keräämisen, sillä yksittäisen drooniprojektin kattama pinta-ala on yleensä korkeintaan muutamia satoja hehtaareja, eikä erillisten maastoaineistojen kerääminen lukuisilta pieniltä alueilta ole taloudellisesti järkevää. Tulosten skaalaaminen suurempaan mittakaavaan vaatii jatkossa erityistä huomiota: tutkimuksessa tulisikin keskittyä kehittämään erityisesti kohteiden suoraa tunnistamista drooniaineistoista ja alueelta toiselle siirrettäviä tilastollisia malleja, jotta droonitulkinnat saataisiin toteutettua riittävällä tarkkuudella ilman toistuvia maastomittauksia. Jos tähän päästään, drooniaineistoja voidaan käyttää myös koulutusaineistona suurempia alueita kattaville malleille. Samalla mahdollistuisi myös autonomisten droonien käyttö suurienkin alueiden tulkinnassa, mikä kuitenkin edellyttäisi myös toiminnan mahdollisten riskien arviointia toimilupien myöntämisen yhteydessä.

Kaukokartoituksen tarkoituksena on tuottaa käyttökelpoista tietoa laajoille alueille riittävän edullisesti. Uusia ilmiöitä ja niiden syitä selvittävälle perustutkimukselle on paikkansa myös kaukokartoituksen alalla, mutta metsällisiin sovelluksiin tähtäävässä tutkimuksessa tulisi jatkossa kiinnittää nykyistä enemmän huomiota menetelmien soveltamiseen suurilla alueilla. Kaukokartoituksen tutkimukselle on usein tyypillistä aineistolähtöisyys, eli keskitytään mallinnuksen keskivirheen minimointiin tai luokittelun tarkkuuden maksimointiin säätämällä malli niin, että se sopii mahdollisimman hyvin käsillä olevaan aineistoon. Mallien siirrettävyyden ja sovellettavuuden kannalta olisi kuitenkin tärkeää keskittyä tunnistamaan ilmiöiden syy-seuraussuhteita ja laatimaan malleja, jotka hyödyntävät niitä. Vaihtoehtoisesti voidaan kehittää fysikaalisia tulkintamenetelmiä, jotka perustuvat suoraan aineistoista tehtäviin mittauksiin ilman tilastollisten mallien käyttöä. Monet tutkimuksessa yleisesti käytetyt koneoppimismenetelmät ovat niin hankalasti ymmärrettäviä, että ilmiöiden syy-seuraussuhteiden selvittäminen voi olla mahdotonta, ja näiden tulkintamenetelmien sovellettavuus oman koulutusaineistonsa ulkopuolella jää usein selvittämättä. Koska kaukokartoituksen tukiaineistoiksi soveltuvat monimuotoisuutta kuvaavat maastoaineistot ovat harvinaisia ja kalliita kerätä, mallien yleistettävyyden näkökulma on tärkeää huomioida monimuotoisuuden kaukokartoituspohjaista tulkintaa kehitettäessä.

Kertainventointien lisäksi käytännön toiminnassa tulisi kiinnittää huomiota myös havaintojen pitkäaikaiseen seurantaan ja todentamiseen. Säilyvätkö esimerkiksi säästöpuut metsissä niin pitkään, että niistä ehtii muodostua lahoppuujatkumoa? Monimuotoisuuden seuranta tulisi jatkossa saada kiinteäksi osaksi metsävaratiedon keruuta, ja siihen tulisi myös suunnata riittävästi resursseja käyttökelpoisen tiedon jatkuvuuden varmistamiseksi. Laserkeilaus- ja ilmakuva-aineistojen tarkkuuden lisäämisen ohella tämä edellyttää myös monimuotoisuuden seurantaan tukevien maastoaineistojen keräämistä esimerkiksi Suomen metsäkeskuksen inventointiprojektien yhteydessä.

## 5.2 Metsäkonetieto

Jotta metsäluonnon monimuotoisuuden mittaamisessa ja dokumentoinnissa metsäkoneiden avulla päästäisiin eteenpäin, tarvitaan sekä mittareiden määrittelyyn että teknologian ja prosessien kehittämiseen keskittyviä toimenpiteitä. Esimerkiksi tarvitaan metsäalan eri sidosryhmien yhdessä

**Taulukko 2.** Tiekartta metsäkonetiedon ja metsäkoneissa olevien sensoreiden tuottaman tiedon hyödyntämisestä metsäluonnon monimuotoisuuden mittaamisessa ja dokumentoinnista Suomessa vuoteen 2030.

Toimenpide	Vuosi									Vastuutoimijat
	2023	2024	2025	2026	2027	2028	2029	2030		
1. Indikaattoreiden määrittely	*									Metsäteollisuus, metsänomistajat, viranomaiset, konevalmistajat
2. Tavoitearvojen asettaminen	*									Metsäteollisuus, metsänomistajat, viranomaiset, konevalmistajat
3. Puomin nivelten anturointi	*	*								Konevalmistajat, tutkimus
4. Sensoriteknologian kehittäminen	*	*	*	*	*	*	*	*	*	Konevalmistajat, koneyritykset, koneenkuljettajat, tutkimus
5. Standardointi	*	*	*	*	*	*	*	*	*	Metsäteho, metsäteollisuus, konevalmistajat
6. Tehokkaammat tietokoneet ja reunalaskenta	*	*	*	*	*	*	*	*	*	Konevalmistajat, tutkimus
7. Visualisointi ja kuljettajan avustaminen	*	*	*	*	*	*	*	*	*	Konevalmistajat, koneyritykset, koneenkuljettajat, tutkimus
8. Tiedon lähettäminen, vastaanottaminen, analysointi ja varastointi	*	*	*	*	*	*	*	*	*	Metsäteollisuus, koneyritykset, konevalmistajat, metsänomistajat, ICT-toimittajat, viranomaiset
9. Tiedon omistajuudesta ja käytöstä sopiminen	*		*		*		*			Metsäteollisuus, koneyritykset, konevalmistajat, metsänomistajat, viranomaiset
10. Investoinnit kalustoon	*	*	*	*	*	*	*	*	*	Koneyritykset
11. Läpinäkyvä raportointi metsäluonnon monimuotoisuudesta		*	*	*	*	*	*	*	*	Metsäteollisuus, koneyritykset, konevalmistajat, metsänomistajat, ICT-toimittajat, viranomaiset

laatima vaatimusmäärittely, joka kuvaa, millä tarkkuudella metsäluonnon monimuotoisuusindikaattoreita mitataan tulevaisuudessa. PEFC ja FSC-sertifiointikriteerit tarjoavat pohjaksi joukon indikaattoreita, mutta metsäkonevalmistajat joutunevat ottamaan huomioon myös uusia indikaattoriehdokkaita tulevaisuuden tuotekehitystyössään (taulukko 2). Tarvitsemme myös kullekin valitulle indikaattorille asetetut tavoitearvot, jotka ovat kaikilla toimijoilla mieluusti samat koko Suomessa, kuten harvennusten korjuujäljen mittaamisessa (vrt. Leivo ym. 2021). Esimerkiksi metsäkoneyritykselle, jonka koneet korjaavat puuta useammalle toimijalle, on helpompaa, kun eri toimijoilla olisi käytössä samat tavoitearvot eri indikaattoreille. Tavoitearvot saattaa kuitenkin olla tarpeellista määrittää eri tavoin Etelä- ja Pohjois-Suomessa.

Teknologia- ja prosessikehittämisessä metsäkonevalmistajien on panostettava siihen, että hakkuulaitteen sijainti on jatkossa tarkka suhteessa hakkuukoneeseen. Tähän keinona on hakkuukoneen puomin kaikkien nivelten anturointi. Metsäkonesensoriteknologian kehittämisessä on myös ensiarvoisen tärkeää sensoriteknologian (esim. laserkeilaimet, konenäkö) ja prosessointimenetelmien kehittäminen metsäkonekäyttöön, ja edelleen niiden tuonti uusiin markkinoille tuleviin metsäkoneisiin. Lisäksi eri sensorijärjestelmien välisten aikamittausten kalibrointia on kehitettävä. Jotta uusilla sensoreilla mitattu tieto saadaan metsäkoneissa täysmääräisesti hyötykäyttöön, tarvitaan tehokkaiden tietokoneiden tuontia metsäkoneisiin, joissa tehdään osin sensoreilla kerätyn monimuotoisuustiedon laskenta reunalaskentana. Metsäkoneissa olevilla sensoreilla tuotetun tiedon lisäksi metsäkoneisiin tullaan tuomaan kaukokartoitettua puukarttatietoa, jota yhdistetään metsäkoneiden sensoritietoon.

Ensiarvoisen tärkeässä roolissa on myös sensoreilla kerätyn uuden monimuotoisuustiedon standardointi ja sen ottaminen StanForD 2010 -metsäkonestandardin piiriin. Kerätyn ja analysoidun monimuotoisuustiedon visualisointiin ja esittämiseen koneenkuljettajalle sekä tiedon hyödyntämiseen metsäkoneessa on panostettava myös tulevina vuosina. Tämä tukee koneenkuljettajan työtä ja sen laadun hallintaa. Paljon tarvitaan myös IT-työtä, että sensoreilla kerätyn uuden

standardoidun monimuotoisuus tiedon lähetys metsäkoneesta vastaanottavaan järjestelmään, varastointi ja analysointi toimivat sujuvasti. IT-kehitystyössä on huomioitava metsäluonnon monimuotoisuusindikaattoreiden läpinäkyvän raportoinnin rakentaminen kultakin puunkorjuutyömaalta metsänomistajalle, urakanantajalle ja Suomen metsäkeskukseen.

Metsäalan eri sidosryhmien on myös sovittava uuden monimuotoisuusmetsäkonetiedon omistajuudesta ja käytöstä. Edellä listatun määrittely- ja kehitystyön jälkeen on vuorossa metsäkoneyrittäjien tekemät investoinnit sellaiseen metsäkonekalustoon, jossa uusi tarkkuuspai-kannus ja sensoriteknologia ovat käytössä. Taulukossa 2 on myös esitetty kunkin toimenpiteen kohdalla, keiden toimijoiden olisi oltava aktiivisia kyseisen toimenpiteen suhteen ja otettava vastuu toimenpiteen toteuttamisesta. Lisäksi taulukon 2 toimenpiteet on aikataulutettu parhaimman käytettävissä olevan tiedon pohjalta.

## 6 Yhteenveto

Kattavan ja luotettavan monimuotoisuus tiedon tuottaminen Suomen talousmetsistä edellyttää sekä kaukokartoituksen että metsäkonetiedon hyödyntämistä. Kaukokartoitusaineistot ovat hehtaari-kustannuksiltaan edullisia ja loppukäyttäjille usein maksuttomasti saatavilla. Kaukokartoitus on kuitenkin nykyisellään riittävän tarkkaa vain osalle monimuotoisuuden kannalta tärkeistä indi-kaattoreista (taulukko 3). Tilanne voi parantua huomattavasti jo vuodesta 2026 alkaen, jos valta-kunnallisen lentolaserkeilausaineiston pulssitiheyttä nostetaan viidestä 20 pulssiin neliömetrillä, ja niin ikään valtakunnallisesti kerättävien ilmakuvien erotuskyky paranee 30:stä kymmeneen senttimetriin. Näihin aineistoihin perustuvia tulkintoja voidaan edelleen tarkentaa kohdennetuilla droonimittauksilla. Droonien potentiaali metsien monimuotoisuuden tulkinnassa on suuri, mutta tulkintamenetelmien kehittäminen vaatii vielä panostusta.

Metsäkonetieto täydentää kaukokartoitustietoa tuottamalla paikallisesti luotettavaa tietoa talousmetsien metsäluonnosta. Nykyisin ja seuraavien lähivuosien aikana esimerkiksi tekopötkelöt, säästöpuuryhmät, arvokkaat luontokohteet sekä vesistöjen ja pienvesien suojavyöhykkeet voidaan

**Taulukko 3.** Yhteenveto monimuotoisuusindikaattoreiden tulkinnan arvioituista tarkkuuksista talousmetsissä eri aineistolähteillä: laserkeilaus 5 pulssia m<sup>-2</sup> ja ilmakuvat, laserkeilaus 20 pulssia m<sup>-2</sup> ja ilmakuvat, droonit (RGB-, moni-kanava- ja hyperspektrikamerat, laserkeilaimet) sekä nykyinen metsäkonetieto ja tulevaisuuden metsäkonesensoritieto. Selite: - tunnistaminen ei onnistu; \*onnistuu rajallisesti; \*\*onnistuu mutta altista virheille, \*\*\*onnistuu luotettavasti.

	Laserkeilaus 5p ja ilmakuvat	Laserkeilaus 20p ja ilmakuvat	Droonit	Metsäkonetieto	Metsäkone- sensoritieto
Säästöpuuryhmät	**	**	***	***	***
Riistatiheiköt	-	-	**	***	***
Suuret pystyyn kuolleet puut ja kelot	*	**	***	*	***
Tekopötkelöt (myös latva hakattu)	-	*	**	***	***
Suuret maalahopuut	-	*	**	*	**
Lahopuun puulaji ja lahon aste	-	-	*	-	*
Haapa ym. vähälukuiset puulajit	*	*	**	-	**
Rakenteellinen monimuotoisuus	***	***	***	-	***
Puuston ikä	*	*	**	-	**
Lehdot ja harvinaiset suotyypit	*	*	**	-	-
Topografialtaan poikkeavat elinympäristöt	***	***	***	-	***
Purot ja norot	**	**	***	-	*
Pienvesien luonnontilaisuus	-	*	**	-	-
Suojavyöhykkeet	***	***	***	***	***
Lajien elinympäristöt ja lajirikkausindeksit	*	*	*	-	-

tallentaa suoraan puunkorjuun yhteydessä ja lisätä edelleen metsävaratietokantoihin (taulukko 3). Koska nykyiset metsäkonetiedostot eivät kykene tarkemman monimuotoisuustiedon, esimerkiksi arvokkaiden isojen haapojen, säästöpuuryhmien puiden lukumäärien, läpimittojen ja puulajien, tai pystyssä olevan lahopuun määrän, todentamiseen, vaan tarvitaan metsäkoneisiin integroitua laserkeilain- ja/tai konenäköpohjaisia sensorijärjestelmiä. Ilmasta kerätty kaukokartoitustieto ja perinteinen metsäkonetieto sekä metsäkoneissa olevilla sensoreilla tuotettu tieto täydentävät ja tukevat toinen toisiaan. Kun esimerkiksi nykyinen kaukokartoitustieto ei pysty todentamaan tehtyjä tekopötkkelöitä, metsäkonetiedolla tämä voidaan toteuttaa.

Yhteenvetona voidaan todeta, että sensoritiedolla rikastettu metsäkonetieto yhdistettynä kaukokartoitustietoon luo tulevana vuosina erinomaisen mahdollisuuden ottaa pitkä loikka metsäluonnon monimuotoisuuden mittaamisessa ja seurannassa sekä metsään jättämämme monimuotoisuuden jalan- ja kädenjäljen raportoinnissa. Loikan ottaminen vaatii kuitenkin merkittäviä TKI-panostuksia teknologioiden kehittämiseksi.

## Liitetiedostot

L1.pdf; Kaukokartoituksen ja metsäkoneiden sensoritekniikka ja tulkintamenetelmät,  
L2.pdf; Kaukokartoituksen ja metsäkonetiedon tulevaisuuden kehitysnäkymiä.  
Molemmat liitteet ovat ladattavissa osoitteesta <https://doi.org/10.14214/ma.23010>.

## Selvitys tutkimusdatan, aineistojen ja ohjelmakoodin avoimuudesta

Katsaus perustuu lähinnä tieteelliseen kirjallisuuteen, jonka avoimuus vaihtelee julkaisusta riippuen. Kirjallisuuden tueksi tehdyt haastattelut eivät ole avoimesti saatavilla, sillä ne suoritettiin vapaamuotoisina ja muistiinpanot kirjattiin pelkästään työn alla olleeseen käsikirjoitukseen.

## Kirjoittajien roolit

Lauri Korhonen ja Kalle Kärhä: tutkimuksen suunnittelu, kirjallisuuden hankinta ja analyysi, haastattelut, tekstin kirjoittaminen ja muokkaaminen, kuvitus.

Jukka Malinen ja Juha Hyypä: kirjallisuuden hankinta ja analyysi, tekstin kirjoittaminen ja muokkaaminen, haastattelut.

Matti Maltamo, Harri Kaartinen, Janne Toivonen, Petteri Packalen ja Matti Koivula: kirjallisuuden hankinta ja analyysi, tekstin kirjoittaminen ja muokkaaminen.

## Kiitokset

Miia Saarimaa (Suomen metsäkeskus) ja Petteri Vihervaara (Suomen ympäristökeskus) antoivat haastatteluissa arvokasta tietoa tutkimuksemme tueksi. Kiitämme myös John Deere Forestry Oy:n, Komatsu Forest Oy:n ja Ponsse Oyj:n henkilöstöä hyvistä keskusteluista liittyen metsäkonetiedon hyödyntämiseen metsäluonnon monimuotoisuuden mittaamisessa. Lisäksi kiitämme Heli Peltolaa, joka vastasi projektin hallinnosta, sekä Alwin Hardenbolia, Anton Kuzminia, Pasi Korpelaista, Timo Melkasta, John Deere Forestry Oy:tä, Komatsu Forest Oy:tä ja Ponsse Oyj:tä, joiden toimittamia kuvamateriaaleja työssä on käytetty.



## Rahoitus

Tämä katsaus on osa puuta jalostavan teollisuuden monimuotoisuustiekarttatyötä ja Suomen Akatemian rahoittamaa tutkimuksen UNITE-lippulaivaa (päättönumero 357906). Metsäteollisuus ry ja Sahateollisuus ry olivat työn toimeksiantajat. Osin katsauksen tekoa rahoitti myös maa- ja metsätalousministeriön rahoittama Kohti ilmastokestävämpää ja monimuotoisempaa puunkorjuuta sensoriteknologian ja tarkan paikkatiedon avulla (IlmoStar) -hanke (2023–2025). Kiitämme kaikkia tutkimuksen rahoittajia. Kiitämme myös nimettäviä vertaisarvioijia rakentavasta palautteesta.

## Kirjallisuus

- Alexander C, Moeslund JE, Bøcher PK, Arge L, Svenning J-C (2013) Airborne laser scanner (LiDAR) proxies for understory light conditions. *Remote Sens Environ* 134: 152–161. <https://doi.org/10.1016/j.rse.2013.02.028>.
- Bauwens S, Bartholomeus H, Calders K, Lejeune P (2016) Forest Inventory with Terrestrial LiDAR: A Comparison of Static and Hand-Held Mobile Laser Scanning. *Forests* 7, article id 127. <https://doi.org/10.3390/f7060127>.
- Bohlin I, Maltamo M, Hedenås H, Lämås T, Dahlgren J, Mehtätalo L (2021) Predicting bilberry and cowberry yields using airborne laser scanning and other auxiliary data combined with National Forest Inventory field plot data. *For Ecol Manage* 502, article id 119737. <https://doi.org/10.1016/j.foreco.2021.119737>.
- Bollandsås OM, Næsset E (2007) Estimating percentile-based diameter distributions in uneven-sized Norway spruce stands using airborne laser scanner data. *Scand J For Res* 22: 33–47. <https://doi.org/10.1080/02827580601138264>.
- Breidenbach J, Næsset E, Lien V, Gobakken T, Solberg S (2010) Prediction of species specific forest inventory attributes using a nonparametric semi-individual tree crown approach based on fused airborne laser scanning and multispectral data. *Remote Sens Environ* 114: 911–924. <https://doi.org/10.1016/j.rse.2009.12.004>.
- Dakin Kuiper S, Coops NC, Jarron LR, Tompalski P, White JC (2023) An automated approach to detecting instream wood using airborne laser scanning in small coastal streams. *Int J Appl Earth Obs Geoinf* 118, article id 103272. <https://doi.org/10.1016/j.jag.2023.103272>.
- Del Perugia B, Giannetti F, Chirici G, Travaglini D (2019) Influence of scan density on the estimation of single-tree attributes by hand-held mobile laser scanning. *Forests* 10, article id 277. <https://doi.org/10.3390/f10030277>.
- Erikson M (2004) Species classification of individually segmented tree crowns in high-resolution aerial images using radiometric and morphologic image measures. *Remote Sens Environ* 91: 469–477. <https://doi.org/10.1016/j.rse.2004.04.006>.
- Forsman M, Holmgren J, Olofsson K (2016) Tree stem diameter estimation from mobile laser scanning using line-wise intensity-based clustering. *Forests* 7, article id 206. <https://doi.org/10.3390/f7090206>.
- Fuentes-Pacheco J, Ruiz-Ascencio J, Rendón-Mancha JM (2015) Visual simultaneous localization and mapping: a survey. *Artif Intell Rev* 43: 55–81. <https://doi.org/10.1007/s10462-012-9365-8>.
- GEO BON (2023) What are EBVs? <https://geobon.org/ebvs/what-are-ebvs/>. Viitattu 5.1.2023.
- Goetz SJ (2006) Remote sensing of riparian buffers: past progress and future prospects<sup>1</sup>. *J Amer Water Reso Assoc* 42: 133–143. <https://doi.org/10.1111/j.1752-1688.2006.tb03829.x>.
- Graf RF, Mathys L, Bollmann K (2009) Habitat assessment for forest dwelling species using LiDAR remote sensing: capercaillie in the Alps. *For Ecol Manage* 257: 160–167. <https://doi.org/10.1016/j.foreco.2009.05.011>.

- org/10.1016/j.foreco.2008.08.021.
- Haavisto V (2023) Luonto- ja luonnonhoitokohteiden automatisoitu tunnistaminen hakkuulaitteen sijaintitiedon avulla. Pro gradu, Itä-Suomen yliopisto, Metsätieteiden osasto. <http://urn.fi/urn:nbn:fi:uef-20231350>.
- Halme P, Kangas A, Kangasoja J, Komonen A, Luoma E, Mäkipää R, Pynnönen S (2022) Metsien kestävyysmuutosten tunnistamiseen tarvitaan yhteiset mittarit. Metsätieteen aikakauskirja, artikkelitunnus10686. <https://doi.org/10.14214/ma.10686>.
- Hannrup B, Bhuiyan N, Möller JJ (2011) Utvärdering av ett system för beräkning och återföring av skördarbaserad information till skogliga register och planeringssystem. Skogforsk Arbetsrapport 757.
- Hardenbol AA, 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 Fenn* 55, article id 10515. <https://doi.org/10.14214/sf.10515>.
- Hardenbol AA, Korhonen L, Kukkonen M, Maltamo M (2023) Detection of standing retention trees in boreal forests with airborne laser scanning point clouds and multispectral imagery. *Methods Ecol Evol* 14: 1610–1622. <https://doi.org/10.1111/2041-210X.13995>.
- Heinara E, Tanhuanpää T, Yrttimaa T, Holopainen M, Vastaranta M (2021) Airborne laser scanning reveals large tree trunks on forest floor. *For Ecol Manage* 491, article id 119225. <https://doi.org/10.1016/j.foreco.2021.119225>.
- Heinara 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 Sens* 15, article id 382. <https://doi.org/10.3390/rs15020382>.
- Helenius L (2021) Laserkeilaus hakkuualoille jätettyjen säästöpuiden tunnistamisessa. Pro gradu -tutkielma, Itä-Suomen yliopisto, Ympäristö- ja biotieteiden laitos. <http://urn.fi/urn:nbn:fi:uef-20211113>.
- Hilli A, Mykrä H, Hokajärvi R, Annala M (2022) Kosteusindeksin hyödyntäminen purojen suoja-  
vyöhykkeiden suunnittelussa. Metsätieteen aikakauskirja, artikkelitunnus 10725. <https://doi.org/10.14214/ma.10725>.
- Hokkanen S (2023) Kasvupaikkatyypin ennustaminen monikanavalaserdatasta. Pro gradu, Itä-Suomen yliopisto, Metsätieteiden osasto. <http://urn.fi/urn:nbn:fi:uef-20230123>.
- Huang L (2021) Review on LiDAR-based SLAM techniques. Teoksessa: 2021 International conference on signal processing and machine learning (CONF-SPML), Stanford, CA, USA, s. 163–168. <https://doi.org/10.1109/CONF-SPML54095.2021.00040>.
- Huo L, Strengbom J, Lundmark T, Westerfelt P, Lindberg E (2023) Estimating the conservation value of boreal forests using airborne laser scanning. *Ecol Ind* 147, article id 109946. <https://doi.org/10.1016/j.ecolind.2023.109946>.
- Hyypä J, Inkinen M (1999) Detecting and estimating attributes for single trees using laser scanner. *The Photogramm J Finland* 16: 27–42.
- Hyypä E, Yu X, Kaartinen H, Hakala T, Kukko A, Vastaranta M, Hyypä J (2020) Comparison of backpack, handheld, under-canopy UAV, and above-canopy UAV laser scanning for field reference data collection in boreal forests. *Remote Sens* 12, article id 3327. <https://doi.org/10.3390/rs12203327>.
- Hyypä E, Kukko A, Kaartinen H, Yu X, Muhojoki J, Hakala T, Hyypä J (2022) Direct and automatic measurements of stem curve and volume using a high-resolution airborne laser scanning system. *Sci Remote Sens* 5, article id 100050. <https://doi.org/10.1016/j.srs.2022.100050>.
- Juote A (2021) Säästöpuiden tunnistaminen latvuston korkeusmallista. Pro gradu, Itä-Suomen yliopisto, Metsätieteiden osasto. <http://urn.fi/urn:nbn:fi:uef-20210594>.
- Jutras-Perreault M-C, Gobakken T, Næsset E, Ørka HO (2023) Comparison of different remotely

- sensed data sources for detection of presence of standing dead trees using a tree-based approach. *Remote Sens* 15, article id 2223. <https://doi.org/10.3390/rs15092223>.
- Kangas A (2006) Sampling rare populations. Teoksessa: Kangas A, Maltamo M (toim) Forest inventory – methodology and applications. *Managing Forest Ecosystems* 10, Springer, s. 119–139. [https://doi.org/10.1007/1-4020-4381-3\\_8](https://doi.org/10.1007/1-4020-4381-3_8).
- Keto-Tokoi P, Siitonen J (2021) Puiden asukkaat. Suomen puiden seuralaislajit. Gaudeamus.
- Kivinen S, Koivisto E, Keski-Saari S, Poikolainen L, Tanhuanpää T, Kuzmin A, Viinikka A, Heikkinen RK, 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. *For Ecol Manage* 462, article id 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. *For Ecol Manage* 473, article id 118327. <https://doi.org/10.1016/j.foreco.2020.118327>.
- Klemas V (2014) Remote sensing of riparian and wetland buffers: an overview. *J Coast Res* 30: 869–880. <https://doi.org/10.2112/JCOASTRES-D-14-00013.1>.
- Korhonen KT, Ahola A, Heikkinen J, Henttonen HM, Hotanen J-P, Ihalainen A, Melin M, Pitkänen J, Rätty M, Sirviö M, Strandström M (2021) Forests of Finland 2014–2018 and their development 1921–2018. *Silva Fenn* 55, article id 10662. <https://doi.org/10.14214/sf.10662>.
- Korhonen L, Salas C, Østgård T, Lien V, Gobakken T, Næsset E (2016) Predicting the occurrence of large-diameter trees using airborne laser scanning. *Can J For Res* 46: 461–469. <https://doi.org/10.1139/cjfr-2015-0384>.
- Korpela I, Ørka HO, Maltamo M, Tokola T, Hyyppä J (2010) Tree species classification using airborne LiDAR – effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fenn* 44: 319–339. <https://doi.org/10.14214/sf.156>.
- Korpela I, Hovi A, Morsdorf F (2012) Understory trees in airborne LiDAR data – selective mapping due to transmission losses and echo-triggering mechanisms. *Remote Sens Environ* 119: 92–104. <https://doi.org/10.1016/j.rse.2011.12.011>.
- Korpela I, Polvivaara A, Papunen S, Jaakkola L, Tienaho N, Uotila J, Puputti T, Flyktman A (2023) Airborne dual-wavelength waveform LiDAR improves species classification accuracy of boreal broadleaved and coniferous trees. *Silva Fenn* 56, article id 22007. <https://doi.org/10.14214/sf.22007>.
- Korpela IS (2008) Mapping of understory lichens with airborne discrete-return LiDAR data. *Remote Sens Environ* 112: 3891–3897. <https://doi.org/10.1016/j.rse.2008.06.007>.
- Kotamaa E (2007) Maalahoppuun määrän ennustaminen laserkeilauksella talousmetsissä. Metsäsuunnittelun ja -ekonomian kandidaatin tutkielma, Joensuun yliopisto, Metsätieteellinen tiedekunta.
- Kukko A, Kaijaluoto R, Kaartinen H, Lehtola VV, Jaakkola A, Hyyppä J (2017) Graph SLAM correction for single scanner MLS forest data under boreal forest canopy. *ISPRS J Photogramm Remote Sens* 132: 199–209. <https://doi.org/10.1016/j.isprsjprs.2017.09.006>.
- Kukkonen M, Maltamo M, Korhonen L, Packalen P (2022) Evaluation of UAS LiDAR data for tree segmentation and diameter estimation in boreal forests using trunk- and crown-based methods. *Can J For Res* 52: 674–684. <https://doi.org/10.1139/cjfr-2021-0217>.
- Kuusinen N, Hovi A, Rautiainen M (2023) Estimation of boreal forest floor lichen cover using hyperspectral airborne and field data. *Silva Fenn* 57, article id 22014. <https://doi.org/10.14214/sf.22014>.
- 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 Sens* 13, article id 1723. <https://doi.org/10.3390/rs13091723>.
- Kärhä K, Ovaskainen H, Palander T (2021) Decision-making among harvester operators in tree selection and need for Advanced Harvester Operator Assistant Systems (AHOASs) on thinning sites. Teoksessa: Chung W, Sessions J, Lyons K, Wigginton K (toim) Proceedings of the Joint 43rd Annual Meeting of Council on Forest Engineering (COFE) & the 53rd International Symposium on Forest Mechanization (FORMEC); Forest Engineering Family – Growing Forward Together, September 27–30, 2021, Corvallis, OR, USA, s 15–25.
- Kärhä K, Haavikko H, Kääriäinen H, Palander T, Eliasson L, Roininen K (2023) Fossil-fuel consumption and CO<sub>2</sub>eq emissions of cut-to-length industrial roundwood logging operations in Finland. *Eur J Forest Res* 142: 547–563. <https://doi.org/10.1007/s10342-023-01541-4>.
- Leivo J, Partanen J, Hytönen H, Haataja L, Pirkonen J, Partamies M, Santapukki R, Nousiainen M (2021) Tarkastusohje, Suomen metsäkeskus.
- Liang X, Wang Y, Jaakkola A, Kukko A, Kaartinen H, Hyypä J, Honkavaara E, Liu J (2015) Forest data collection using terrestrial image-based point clouds from a handheld camera compared to terrestrial and personal laser scanning. *IEEE Trans Geosci Remote Sens* 53: 5117–5132. <https://doi.org/10.1109/TGRS.2015.2417316>.
- Liang X, Wang Y, Pyörälä J, Lehtomäki M, Yu X, Kaartinen H, Kukko A, Honkavaara E, Issaoui AEI, Nevalainen O, Vaaja M, Virtanen J-P, Katoh M, Deng S (2019) Forest in situ observations using unmanned aerial vehicle as an alternative of terrestrial measurements. *For Ecosyst* 6, article id 20. <https://doi.org/10.1186/s40663-019-0173-3>.
- Lindberg E, Roberge J-M, Johansson T, Hjältén J (2015) Can Airborne Laser Scanning (ALS) and forest estimates derived from satellite images be used to predict abundance and species richness of birds and beetles in boreal forest? *Remote Sens* 7: 4233–4252. <https://doi.org/10.3390/rs70404233>.
- Maltamo M, Packalén P, Yu X, Eerikäinen K, Hyypä J, Pitkänen J (2005) Identifying and quantifying structural characteristics of heterogeneous boreal forests using laser scanner data. *For Ecol Manage* 216: 41–50. <https://doi.org/10.1016/j.foreco.2005.05.034>.
- Maltamo M, Kallio E, Bollandsås OM, Næsset E, Gobakken T, Pesonen A (2014) Assessing Dead wood by airborne laser scanning. Teoksessa: Maltamo M, Næsset E, Vauhkonen J (toim) Forestry applications of Airborne Laser Scanning: concepts and case studies. *Managing Forest Ecosystems* 27. Springer Netherlands, Dordrecht, s. 375–395. [https://doi.org/10.1007/978-94-017-8663-8\\_19](https://doi.org/10.1007/978-94-017-8663-8_19).
- Maltamo M, Kinnunen H, Kangas A, Korhonen L (2020) Predicting stand age in managed forests using National Forest Inventory field data and airborne laser scanning. *For Ecosyst* 7, article id 44. <https://doi.org/10.1186/s40663-020-00254-z>.
- Maltamo M, Packalén P, Kangas A (2021) From comprehensive field inventories to remotely sensed wall-to-wall stand attribute data – a brief history of management inventories in the Nordic countries. *Can J For Res* 51: 257–266. <https://doi.org/10.1139/cjfr-2020-0322>.
- Melin M, Mehtätalo L, Miettinen J, Tossavainen S, Packalén P (2016) Forest structure as a determinant of grouse brood occurrence – an analysis linking LiDAR data with presence/absence field data. *For Ecol Manage* 380: 202–211. <https://doi.org/10.1016/j.foreco.2016.09.007>.
- Melkas T, Riekkö K (2017) The positioning accuracy of trees based on harvester location and harvester head position measurements – a computational algorithm for improving the estimate for harvester head position. *Metsätehon tulokset* 9b/2017. <https://www.metsateho.fi/the-positioning-accuracy-of-trees-based-on-harvester-location/>.
- Melkas T, Riekkö K, Sorsa J-A (2020) Automated method for delineating harvested stands based on harvester location data. *Remote Sens* 12, article id 2754. <https://doi.org/10.3390/rs12172754>.



- Metsäkeskus (2022a) Tulkintasuosituksia metsälain 10 pykälän tarkoittamien erityisen tärkeiden elinympäristöjen rajaamisesta ja käsittelystä. <https://www.metsakeskus.fi/sites/default/files/document/metsalain-10-pykalan-kohteiden-tulkintasuositus.pdf>. Viitattu 15.1.2023.
- Metsäkeskus (2022b) Luonnonhoidon paikkatietoaineistot. <https://storymaps.arcgis.com/stories/017240466fba495892f15c6e0b339849>. Viitattu 30.8.2023.
- Miura N, Jones SD (2010) Characterizing forest ecological structure using pulse types and heights of airborne laser scanning. *Remote Sens Environ* 114: 1069–1076. <https://doi.org/10.1016/j.rse.2009.12.017>.
- Moeslund JE, Zlinszky A, Ejrnæs R, Brunbjerg AK, Bøcher PK, Svenning J-C, Normand S (2019) Light detection and ranging explains diversity of plants, fungi, lichens, and bryophytes across multiple habitats and large geographic extent. *Ecol Appl* 29, article id e01907. <https://doi.org/10.1002/eap.1907>.
- Mohamedou C, Tokola T, Eerikäinen K (2014) Applying airborne  $\gamma$ -ray and DEM-derived attributes to the local improvement of the existing individual-tree growth model for diameter increment. *Remote Sens Environ* 155: 248–256. <https://doi.org/10.1016/j.rse.2014.08.033>.
- Mononen L, Auvinen A-P, Packalen P, Virkkala R, Valbuena R, Bohlin I, Valkama J, Vihervaara P (2018) Usability of citizen science observations together with airborne laser scanning data in determining the habitat preferences of forest birds. *For Ecol Manage* 430: 498–508. <https://doi.org/10.1016/j.foreco.2018.08.040>.
- Müller J, Vierling K (2014) Assessing biodiversity by airborne laser scanning. Teoksessa: Maltamo M, Næsset E, Vauhkonen J (toim) *Forestry applications of airborne laser scanning: concepts and case studies*. Springer Netherlands, Dordrecht, s. 357–374.
- 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 Sens Environ* 256, article id 112322. <https://doi.org/10.1016/j.rse.2021.112322>.
- Nevalainen P, Li Q, Melkas T, Riekkilä K, Westerlund T, Heikkonen J (2020) Navigation and mapping in forest environment using sparse point clouds. *Remote Sens* 12, article id 4088. <https://doi.org/10.3390/rs12244088>.
- Paakkari J (2023) Erityisen tärkeiden elinympäristöjen tunnistaminen paikkatietoaineistolla. Pro gradu, Itä-Suomen yliopisto, Metsätieteiden osasto. <http://urn.fi/urn:nbn:fi:uef-20230255>.
- Packalén P, Maltamo M (2008) Estimation of species-specific diameter distributions using airborne laser scanning and aerial photographs. *Can J For Res* 38: 1750–1760. <https://doi.org/10.1139/X08-037>.
- 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. *For Ecol Manage* 538, article id 120993. <https://doi.org/10.1016/j.foreco.2023.120993>.
- Pesonen A (2011) Comparison of field inventory methods and use of airborne laser scanning for assessing coarse woody debris. *Diss For* 113. <https://doi.org/10.14214/df.113>.
- Pesonen A, Maltamo M, Eerikäinen K, Packalén P (2008) Airborne laser scanning-based prediction of coarse woody debris volumes in a conservation area. *For Ecol Manage* 255: 3288–3296. <https://doi.org/10.1016/j.foreco.2008.02.017>.
- Peura M, Silveyra Gonzalez R, Müller J, Heurich M, Vierling LA, Mönkkönen M, Bässler C (2016) Mapping a ‘cryptic kingdom’: performance of lidar derived environmental variables in modelling the occurrence of forest fungi. *Remote Sens Environ* 186: 428–438. <https://doi.org/10.1016/j.rse.2016.09.003>.
- Pippuri I, Maltamo M, Packalen P, Mäkitalo J (2013) Predicting species-specific basal areas in



- urban forests using airborne laser scanning and existing stand register data. *Eur J Forest Res* 132: 999–1012. <https://doi.org/10.1007/s10342-013-0736-8>.
- Pippuri I, Suvanto A, Maltamo M, Korhonen KT, Pitkänen J, Packalen P (2016) Classification of forest land attributes using multi-source remotely sensed data. *Int J Appl Earth Obs Geoinf* 44: 11–22. <https://doi.org/10.1016/j.jag.2015.07.002>.
- Reddy CS (2021) Remote sensing of biodiversity: what to measure and monitor from space to species? *Biodivers Conserv* 30: 2617–2631. <https://doi.org/10.1007/s10531-021-02216-5>.
- Reddy CS, Kurian A, Srivastava G, Singhal J, Varghese AO, Padalia H, Ayyappan N, Rajashekar G, Jha CS, Rao PVN (2021) Remote sensing enabled essential biodiversity variables for biodiversity assessment and monitoring: technological advancement and potentials. *Biodivers Conserv* 30: 1–14. <https://doi.org/10.1007/s10531-020-02073-8>.
- Riekkä K, Malinen J (2022a) Poistumakuviointi hakkuulaitteen sijaintitiedoista. *Metsätehon tulosalvosarja* 8/2022. <https://www.metsateho.fi/wp-content/uploads/Tulosalvosarja-2022-08-Poistumakuviointi-hakkuulaitteen-sijaintitiedosta.pdf>.
- Riekkä K, Malinen J (2022b) Suojavyöhykkeiden leveyden laskennallinen määrittäminen hakkuukonetiedoista. *Metsätehon tulosalvosarja* 9/2022. <https://www.metsateho.fi/wp-content/uploads/Tulosalvosarja-2022-9-Suojavyohykkeiden-leveyden-laskennallinen-maarittaminen-hakkuukonetiedosta.pdf>.
- Risutec (2021) Datasheet – ASTA-ex mounted marking and guidance for all carriers in forest & field. <https://risutec.fi/wp-content/uploads/2021/08/ASTA-ex-Datasheet-1.pdf>. Viitattu 4.2.2024.
- Rocchini D, Torresani M, Beierkuhnlein C, Feoli E, Foody GM, Lenoir J, Malavasi M, Moudry V, Šimová P, Ricotta C (2022) Double down on remote sensing for biodiversity estimation: a biological mindset. *Commun Ecol* 23: 267–276. <https://doi.org/10.1007/s42974-022-00113-7>.
- Räty J, Packalen P, Maltamo M (2018) Comparing nearest neighbor configurations in the prediction of species-specific diameter distributions. *Ann of For Sci* 75: 1–16. <https://doi.org/10.1007/s13595-018-0711-0>.
- Räty J, Packalen P, Kotivuori E, Maltamo M (2020) Fusing diameter distributions predicted by an area-based approach and individual-tree detection in coniferous-dominated forests. *Can J For Res* 50: 113–125. <https://doi.org/10.1139/cjfr-2019-0102>.
- Saarinen N, Vastaranta M, Näsi R, Rosnell T, Hakala T, Honkavaara E, Wulder MA, Luoma V, Tommaselli AMG, Imai NN, Ribeiro EAW, Guimarães RB, Holopainen M, Hyyppä J (2018) Assessing biodiversity in boreal forests with UAV-based photogrammetric point clouds and hyperspectral imaging. *Remote Sens* 10, article id 338. <https://doi.org/10.3390/rs10020338>.
- Schiefer F, Schmidlein S, Frick A, Frey J, Klinke R, Zielewska-Büttner K, Junttila S, Uhl A, Kattenborn T (2023) UAV-based reference data for the prediction of fractional cover of standing deadwood from Sentinel time series. *ISPRS Open J Photogr Remote Sens* 8, article id 100034. <https://doi.org/10.1016/j.ophoto.2023.100034>.
- Schumacher J, Hauglin M, Astrup R, Breidenbach J (2020) Mapping forest age using National Forest Inventory, airborne laser scanning, and Sentinel-2 data. *For Ecosys* 7, article id 60. <https://doi.org/10.1186/s40663-020-00274-9>.
- Seppälä P, Malinen J, Riekkä K, Ovaskainen H, Strandström M, Räsänen T, Poikela A, Sorsa J-A (2021) Metsätiedon palvelualusta puunkorjuun laadunhallinnassa ja talousmetsän luonnonhoidon todentamisessa. *Metsätehon raportti* 262. <https://www.metsateho.fi/wp-content/uploads/Raportti-262-Metsätiedon-palvelualusta-puunkorjuun-laadunhallinnassa.pdf>.
- Skidmore AK, Coops NC, Neinavaz E, Ali A, Schaepman ME, Paganini M, Kissling WD, Vihervaara P, Darvishzadeh R, Feilhauer H, Fernandez M, Fernández N, Gorelick N, Geijzen-dorffer I, Heiden U, Heurich M, Hobern D, Holzwarth S, Muller-Karger FE, Van De Kerchove R, Lausch A, Leitão PJ, Lock MC, Múcher CA, O’Connor B, Rocchini D, Roeeesli C, Turner

- W, Vis JK, Wang T, Wegmann M, Wingate V (2021) Priority list of biodiversity metrics to observe from space. *Nat Ecol Evol* 5: 896–906. <https://doi.org/10.1038/s41559-021-01451-x>.
- Skogforsk (2021) StanForD 2010 – modern communication with forest machines. <https://www.skogforsk.se/english/projects/stanford/stanford-2010/>.
- Sodhi NS, Ehrlich PR (toim) (2010) Conservation biology for all. Oxford University Press, Oxford, New York. [https://conbio.org/images/content\\_publications/ConservationBiology-forAll\\_reducedsize.pdf](https://conbio.org/images/content_publications/ConservationBiology-forAll_reducedsize.pdf).
- Ståhl G, Gove JH, Williams MS, Ducey MJ (2010) Critical length sampling: a method to estimate the volume of downed coarse woody debris. *Eur J For Res* 129: 993–1000. <https://doi.org/10.1007/s10342-010-0382-3>.
- Sumnall M, Fox TR, Wynne RH, Thomas VA (2018) Mapping the height and spatial cover of features beneath the forest canopy at small-scales using airborne scanning discrete return Lidar. *ISPRS J Photogramm Remote Sens* 133: 186–200. <https://doi.org/10.1016/j.isprsjprs.2017.10.002>.
- Sverdrup-Thygeson A, Ørka HO, Gobakken T, Næsset E (2016) Can airborne laser scanning assist in mapping and monitoring natural forests? *For Ecol Manage* 369: 116–125. <https://doi.org/10.1016/j.foreco.2016.03.035>.
- Säynäjoki R, Packalén P, Maltamo M, Vehmas M, Eerikäinen K (2008) Detection of aspens using high resolution aerial laser scanning data and digital aerial images. *Sensors* 8: 5037–5054. <https://doi.org/10.3390/s8085037>.
- Taipale E, Riekkö K, Melkas T, Malinen J (2022) Hakkuupään sijaintitiedon tarkkuus. Metsätehon tulosalvosarja 1/2022. <https://www.metsateho.fi/wp-content/uploads/Tulosalvosarja-2022-01-Hakkuupaan-sijaintitiedon-tarkkuus.pdf>.
- Tanhuanpää T, Kankare V, Vastaranta M, Saarinen N, Holopainen M (2015) Monitoring downed coarse woody debris through appearance of canopy gaps in urban boreal forests with bitemporal ALS data. *Urb Forestry Urb Green* 14: 835–843. <https://doi.org/10.1016/j.ufug.2015.08.005>.
- Toivonen J, Kangas A, Maltamo M, Kukkonen M, Packalen P (2023). Assessing biodiversity using forest structure indicators based on airborne laser scanning data. *For Ecol Manage* 546, article id 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. *Can J For Res*. <https://doi.org/10.1139/cjfr-2023-0271>.
- Tolonen J, Leka J, Yli-Heikkilä K, Hämäläinen L, Halonen L (2019) Pienvesiopas. Pienvesien tunnistaminen ja lainsäädäntö. Suomen ympäristökeskuksen raportteja 36. <http://hdl.handle.net/10138/306503>.
- Triona (2020) Hakkuukonetiedon laskentapalvelu valmiina pilotointiin. Uutiset 23.11.2020. <https://www.triona.fi/uutisia/2020/hakkuukonetiedon-laskentapalvelu-valmiina-pilotointiin/>. Viitattu 4.2.2024.
- Tuominen S, Näsi R, Honkavaara E, Balazs A, Hakala T, Viljanen N, Pölönen 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 Sens* 10, article id 714. <https://doi.org/10.3390/rs10050714>.
- Valbuena R (2015) Forest structure indicators based on tree size inequality and their relationships to airborne laser scanning. *Diss For* 205. <https://doi.org/10.14214/df.205>.
- Valbuena R, O'Connor B, Zellweger F, Simonson W, Vihervaara P, Maltamo M, Silva CA, Almeida DRA, Danks F, Morsdorf F, Chirici G, Lucas R, Coomes DA, Coops NC (2020) Standardizing ecosystem morphological traits from 3D information sources. *Trends Ecol Evol* 35: 656–667. <https://doi.org/10.1016/j.tree.2020.03.006>.
- Vauhkonen J, Imponen J (2016) Unsupervised classification of airborne laser scanning data to locate

- potential wildlife habitats for forest management planning. *Forestry* 89: 350–363. <https://doi.org/10.1093/forestry/cpw011>.
- Vehmas M, Eerikäinen K, Peuhkurinen J, Packalén P, Maltamo M (2009) Identification of boreal forest stands with high herbaceous plant diversity using airborne laser scanning. *For Ecol Manage* 257: 46–53. <https://doi.org/10.1016/j.foreco.2008.08.016>.
- Vehmas M, Eerikäinen K, Peuhkurinen J, Packalén P, Maltamo M (2011a) Airborne laser scanning for the site type identification of mature boreal forest stands. *Remote Sens* 3: 100–116. <https://doi.org/10.3390/rs3010100>.
- Vehmas M, Packalén P, Maltamo M, Eerikäinen K (2011b) Using airborne laser scanning data for detecting canopy gaps and their understory type in mature boreal forest. *Ann For Sci* 68: 825–835. <https://doi.org/10.1007/s13595-011-0079-x>.
- Vihervaara P, Mononen L, Auvinen A-P, Virkkala R, Lü Y, Pippuri I, Packalen P, Valbuena R, Valkama J (2015) How to integrate remotely sensed data and biodiversity for ecosystem assessments at landscape scale. *Landscape Ecol* 30: 501–516. <https://doi.org/10.1007/s10980-014-0137-5>.
- 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 Ecol Conserv* 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* 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 Sens* 12, article id 2610. <https://doi.org/10.3390/rs12162610>.
- Yrttimaa T, Saarinen N, Luoma V, Tanhuanpää T, Kankare V, Liang X, Hyypä J, Holopainen M, Vastaranta M (2019) Detecting and characterizing downed dead wood using terrestrial laser scanning. *ISPRS J Photogr Remote Sens* 151: 76–90. <https://doi.org/10.1016/j.isprsjprs.2019.03.007>.
- Zielewska-Büttner K, Adler P, Kolbe S, Beck R, Ganter LM, Koch B, Braunisch V (2020) Detection of standing deadwood from aerial imagery products: two methods for addressing the bare ground misclassification issue. *Forests* 11, article id 801. <https://doi.org/10.3390/f11080801>.
- Ørka H, Næsset E, Bollandsås OM (2007). Utilizing airborne laser intensity for tree species classification. *Int Arch Photogram Remote Sens Spat Inform Sci* 36: 300–304.

115 viitettä.

## Haastattelut

- Seppo Kontteli ja Jari Nurminen, Komatsu Forest Oy, 16.1.2023.
- Kalle Einola, Juha Inberg, Jukka Laitinen, Tuomo Moilanen ja Markku Savolainen, Ponsse Oyj, 17.1.2023.
- Marko Paakkunainen, Niko Solopuro, Sakari Suuriniemi ja Sami Törmä, John Deere Forestry Oy, 17.1.2023.
- Petteri Vihervaara, Suomen ympäristökeskus (Syke), 19.1.2023.
- Miia Saarimaa, Suomen metsäkeskus, 20.1.2023.