

Liite L2. Kaukokartoituksen ja metsäkonetiedon tulevaisuuden kehitysnäkymiä

1 Kaukokartoitus

Kaukokartoitukselle on tutkimusalan leimallista sensoritekniikan nopea kehittyminen sekä siitä seuraava aineistojen yhtäaikainen halpeneminen ja tarkkuuden kasvu. Esimerkiksi laserkeilausaineistoa kerätään nykyään yksinpuintulkintaan riittävällä tarkkuudella 2–3 km korkeudelta. Mitä ylempää tarkkaa aineistoa voidaan kerätä, sitä edullisemmaksi se tulee, sillä korkeammalta havaitaan kerralla suurempi alue. Tietyt fysikaaliset rajoitteet kuitenkin säilyvät: esimerkiksi sensoriin saapuvan säteilyn määrä on rajallinen, joten sensori ei voi yhtä aikaa havainnoida laajaa maantieteellistä aluetta hyvin monella aallonpituuskanavalla ja kyetä silti erottelemaan säteilyn voimakkuuseroja erittäin tarkasti. Tästä syystä esimerkiksi korkean resoluution satelliittikuvat, jotka vastaavat tarkkuudeltaan ilmakuvia, kattavat vain pieniä alueita kerrallaan, vaikka kuvauskorkeus on useita satoja kilometrejä.

Kaukokartoitustulkintojen kehitys seuraa suoraan sensoritekniikan kehitystä. Monimuotoisuuden kaukokartoituksen kannalta tärkein aineistolähde Suomessa on lentolaserkeilaus, jonka kyky erottaa monimuotoisuuden kannalta oleellisia yksityiskohtia riippuu aineiston pulssitiheydestä ja pulssin halkaisijasta maanpinnalla. Vuonna 2020 alkaneella Suomen toisella valtakunnallisella laserkeilauskierröksellä keilaimen lähettämää pulssitiheyttä nostettiin yhdestä viiteen pulssiin neliometrillä. Vuonna 2026 alkaa todennäköisesti laserkeilaus kolmas valtakunnallinen sykli, jonka yksityiskohtia ei ole vielä päätetty, mutta piloteissa testataan pulssitiheyden nostamista 10 tai 20 pulssiin neliometrillä. Samalla pulssin halkaisija maanpinnalla olisi myös pidettävä pienenä, sillä suurta halkaisijaa käytettäessä energiaa palautuu helpommin useasta kohteesta yhtä aikaa, mikä vaikeuttaa pienten yksityiskohtien tunnistamista. Käytännössä kapea pulssi vaatinee jatkossakin lentämistä alempana.

Monimuotoisuuden kaukokartoituksen kannalta laserkeilaus erotuskyvyn kasvu olisi erittäin toivottavaa, sillä esimerkiksi maa- ja pystylahopuun luotettava tunnistaminen suoraan pistepilvestä vaatii korkeaa pistetiheyttä (Heinara ym. 2023; Huo ym. 2023). Samoin latvuserroksen alle jäävät alikasvospuut, pensaat sekä kenttä- ja pohjakerroksen kasvillisuus on helpompi tunnistaa tiheämmästä aineistosta. Suurempi pistetiheys avaa uusia mahdollisuuksia myös puulajitulkintaan, sillä yksittäisten latvojen rakenneerojen havainnointi helpottuu. Mahdollisesti 2030-luvulla lentolaserkeilaustekniikassa ja tulkintamenetelmissä päästään tarkkuustasolle, jossa näitä metsien monimuotoisuuteen olennaisesti liittyviä piirteitä pystytään tunnistamaan pistepilvestä suurille alueille päätöstukeen riittävällä tarkkuudella. Samalla metsävaratietoon voidaan tuoda entistä enemmän puutason informaatiota nykyisten kuviokohtaisten keskitunnusten lisäksi. Esimerkiksi tieto erityisen suurikokoisista elävistä ja kuolleista puista, järeistä lehtipuista tai harvinaisista puulajeista olisi arvokasta suojelutoimien kohdentamisen kannalta. Nykyään jo operationaalinen ylis- ja säästöpuiden kartoitus tulisi jatkossa laajentaa koskemaan kaikkia metsissä olevia suurikokoisia ja muilla tavoin arvokkaita puita, sillä monimuotoisuuden kannalta merkityksellisintä on niiden kokonaismäärä kaikenlaiset metsät huomioiden. Paikkatietokeskus on jo toteuttanut pilottina pilvipalvelupohjaisen yksinpuintulkintapalvelun metsakanta.com, jonka karttanäkymästä voi tarkastella nykyisestä 5 pulssia/m² laserkeilausaineistosta tunnistettuja puita sekä niiden puulajikohtaisia pituus- ja läpimittajakaumia. Tiedot lasketaan Maanmittauslaitoksen avoimen laserkeilausdatan perusteella. Kartta visualisoi puuston alueellista jakautumista, ja tarjoaa tietoa niin hakkuu- kuin suojelumahdollisuuksistakin.

Droonien käyttöä rajoittaa tällä hetkellä lainsäädäntö, sillä droonilla lentäminen yli 120 metrin korkeuksilla tai ilman tähytystä vaatii erityisluvan. Sallituilla korkeuksilla lennettäessä jo nykyensoreilla saadaan erittäin tarkkoja kuvia ja pistepilviä, joista näkyy pieniäkin yksityiskohtia. Droonikaukokartoituksen

suurimmat haasteet liittyvät tulkintamenetelmien kehittämiseen ja kustannustehokkuuden parantamiseen. Drooneilla saatavat aineistot sisältävät massiivisia määriä tietoa, mutta toistaiseksi niiden tulkinta on ollut usein visuaalista. Tulevaisuudessa vastaavia tulkintoja voidaan mahdollisesti tehdä syväoppivien neuroverkkojen avulla, mistä on jo lupaavia tutkimustuloksia. Esimerkiksi Kattenborn ym. (2019) tunnistivat neuroverkon avulla Montereynmännyn (*Pinus radiata* D. Don) sekä eri kahden eri pensaslajin esiintymiä Chilestä kerätyiltä droonikuvamosaiikeilta. Hell ym. (2022) luokittelivat Saksassa havu-, lehti- ja kuolleita puita neuroverkkopohjaisesti tiheään laserkeilausaineiston ja monikanavaimakuvien avulla parhaimmillaan 87 % tarkkuudella. Puliti ym. (2023) mittasivat Norjassa havupuuston kasvua suoraan droonilaserkeilatusta 3D-pistepilvestä segmentoimalla vuosikasvaimet erilleen neuroverkon avulla.

Tämäntapaisten menetelmien kehittäminen riittävän tarkoiksi ja Suomen olosuhteisiin sopiviksi vaatii kuitenkin huomattavia panostuksia alan tutkimukseen, ja erityisesti mallien kouluttamisessa käytettävien aineistojen keräämiseen. Kun drooneilla kerättyjä ilmakuvia koostetaan yhteen suurien alueiden kartoittamista varten, mm. varjojen, sääolojen, vuodenajan ja puuston rakenteellisten erojen aiheuttamien vaihtelujen huomioiminen aineistojen analysoinnissa ei ole yksinkertaista. Ongelmia voidaan vähentää paikallisen kalibroinnin avulla (Li ym. 2023). Drooneihin asennettavat laserkeilaimet voivat kuitenkin olla suuraluetulkintojen kannalta monikanava- tai hyperspektrikuvia luotettavampi tapa kerätä tietoa, mutta ne ovat toistaiseksi kalliita hankkia. Koska aineistojen määrät ovat droonitulkinnoissa erittäin suuria, niiden analysointi on järkevintä toteuttaa pilvilaskentana, mikä vaatii runsaasti tallennus- ja tiedonsiirto-kapasiteettia. Suomessa aihepiiriä tutkitaan eri tutkimuslaitosten lisäksi monissa yrityksissä. Esimerkiksi Kelluu Oy kehittää ympäristön seurantaan autonomisten ilmalaivojen avulla ja CollectiveCrunch Oy koneoppimismenetelmiä hiilensidonnan ja monimuotoisuuden seurantaan.

Satelliittikaukokartoituksessa tärkein kehityssuunta on käytettävissä olevien sävyarvokanavien lisääntyminen, mutta myös kuvien erotuskyky ja saatavuus ovat parantuneet huomattavasti. Esimerkiksi vuonna 2015 laukaistu Sentinel-2-satelliitti toi mukanaan uusia, erityisesti kasvillisuuden havainnointiin suunniteltuja sävyarvokanavia, joiden avulla erityisesti puulajitulkinnan tarkkuus on parantunut (Kukkonen ym. 2018; Persson ym. 2018; Hemmerling ym. 2021). Tulevista satelliittiohjelmista kiinnostavia ovat mm. Landsat NEXT (2030), CHIME (2028) ja Kuva Space. Landsat NEXT tulee sisältämään kolme identtistä satelliittia, joista jokainen kuvaa Landsat-ohjelman aiemmista satelliiteista tuttujen 11 sävyarvokanavan lisäksi 15 kokonaan uutta kanavaa, joiden erotuskyky maanpinnalla on 10–60 m. CHIME-järjestelmä tulee koostumaan kahdesta satelliitista, joiden kantamat hyperspektrisensoreit pystyvät erottamaan yli 200 sävyarvokanavaa 30 m erotuskyvyllä aiempia vastaavia satelliitteja huomattavasti leveämmältä 130 km kaistalta. Suomalainen Kuva Space kehittää puolestaan kasvillisuustulkintaan soveltuvia hyperspektrisensoreita kantavien mikrosatelliittien parvea.

Ilma- ja satelliittikuva-aineistojen paraneva kyky erottaa säteilyn eri aallonpituuksia on nostanut uudeksi tutkimusaiheeksi spektrisen eli kasveista heijastuneen säteilyn monimuotoisuuden (Rossi ym. 2021; Kacic ja Kuenzer 2022). Spektrinen monimuotoisuus perustuu siihen, että eri kasvilajien ominaispiirteet vaikuttavat myös niiden spektriin eli tapaan, jolla ne heijastavat sähkömagneettista säteilyä eri aallonpituuksilla (Schweiger ym. 2018). On esitetty, että spektristä monimuotoisuutta voitaisiin käyttää suoraan metsäluonnon monimuotoisuutta kuvaavana indikaattorina (Kacic ja Kuenzer 2022), mutta sen avulla ei todennäköisesti voida kuvata kuin pieni osa lajiston kokonaisrikkaudesta (Perrone ym. 2023). Joka tapauksessa kaukokartoitusaineistojen laadun parantuessa paranevat myös mahdollisuudet tunnistaa eri kasvilajeja suoraan havainnoimalla niiden heijastamaa säteilyä. Tämä kuitenkin edellyttää, että saatavilla on ns. spektripankkeja, joihin eri kasvilajien tunnusomaisia heijastusspektrejä on kerätty. Spektrisen monimuotoisuuden kartoituksen tueksi on kerätty Suomestakin laajoja aineistoja mm. eri puulajien lehtien ja kuoren sekä aluskasvillisuuden heijastusspektreistä, ja työ tulee jatkossa laajenemaan mm. monimuotoisuuden kannalta arvokkaisiin kasvilajeihin (Rautiainen ym. 2022). Tämä on eräs lupaava, mutta myös haastava kaukokartoituksen osa-alue, jonka kehittäminen vaatii pitkäjänteistä työtä.

2 Metsäkonetieto

Arvioitaessa tulevaisuuden kehitysnäkymiä ja -mahdollisuuksia metsäluonnon monimuotoisuuden mittaamisessa ja seurannassa on hyvä nostaa esille, millä tarkkuustasolla monimuotoisuusindikaattoreita on tarvetta mitata ja dokumentoida. Sanomattakin on selvää, että suojavyöhykkeiden leveyksien mittaamisessa esimerkiksi viiden metrin tarkkuustaso on liian karkea. Sen sijaan esimerkiksi säästöpuuryhmien, tekopökkelöiden tai riistatiheiköiden sijaintitarkkuutena viisi metriä on riittävä lähivuosina. Oletettavaa on, että jatkossa kuitenkin vaatimustaso näidenkin sijaintitarkkuuksien suhteen nousee.

Mitä tulee lähivuosina metsäkonetiedostojen hyödyntämiseen metsäluonnon monimuotoisuuden dokumentoinnissa puunkorjuuoperaatioiden yhteydessä, voidaan arvioida, että tällä hetkellä tärkein asia on saada hakkuukoneen hakkuulaitteen sijaintitiedon tarkkuus nykyistä paremmalle, vähintään 1–2 metrin tasolle. Nykyistä (keskimäärin 4–5 m) tarkempi hakkuulaitteen sijaintitieto mahdollistaa jatkossa esimerkiksi vesistöjen ja pienvesien suojavyöhykkeiden hakkuun siten, että suojavyöhyke on varmasti riittävän leveä. On ennustettavissa, että 1–2 m sijaintitarkkuuden kehittäminen vie aikaa, koska heikkojen verkkoyhteyksien ja metsässä muodostuvien katvealueiden vuoksi nopeaa datayhteyttä ei ole aina saatavilla.

Viimeaikaiset UNITE-lippulaivan järjestämät Luken, Paikkatietokeskuksen ja Itä-Suomen yliopiston yhteistutkimukset metsäkoneiden paikantamisessa ovat olleet lupaavia. Kevättalvella 2022 tehdyssä metsäkoneen paikannustestissä satelliittinäkyvyydeltään haastavassa harvennushakkuukohteessa päästiin alle 60 cm:n paikannustarkkuuteen maanmittaustason RTK-GNSS-laitteella, kun korjausdata oli käytettävissä. Samassa testissä metsäkoneeseen oli asennettu myös pienikokoinen GNSS-IMU (Inertial Measurement Unit) -paikannin, jolla paikannustarkkuuden keskivirhe (root mean square error, RMSE) jälkilaskennalla oli 35 cm (Kaartinen ym. 2024).

Galileo-satellittipaikannusjärjestelmän HAS (High Accuracy Service) -palvelussa korjausdata saadaan suoraan vastaanottimeen Galileon E6-B-signaalin mukana, jolloin paikannustarkkuuden parantaminen onnistuu myös täysin ilman datayhteyttä. Korjaus tukee sekä Galileo- että GPS-järjestelmiä. HAS-palvelu julkaistiin koekäyttöön tammikuussa 2023, ja hyvissä olosuhteissa paikannustarkkuuden luvataan olevan vähintään 20 cm. Onkin mielenkiintoista nähdä, päästäänkö HAS-järjestelmän tuella 1–2 metrin paikannustarkkuuteen metsän sisällä jo lähivuosina. Voidaan arvioida, että edellä mainittuun paikannustarkkuuteen päästään viimeistään 2020-luvun loppupuolella.

Runkokoodia (StemCode) voidaan hyödyntää hakkuussa vain käsiteltävien runkojen merkitsemiseen; esimerkiksi käsitellessään tekopökkelörunkoa kolmen metrin korkeudelta hakkuukoneenkuljettaja antaa runkokoodin 1. Tällöin tehty tekopökkelö ja sen sijainti kirjautuvat hpr-tiedostoon. Täten voidaan raportoida hakkuualueelle tehtyjen tekopökkelöiden lukumäärä (kpl/ha) sijainteineen. Jos tehdyn tekopökkelön latvaa ei karsita ja siitä ei tehdä esimerkiksi kuitupuupölkkyä, runkokooditusta ei voida käyttää.

Toisaalta hakkuukoneenkuljettaja voisi myös viedä hakkuulaitteen säästöpuuryhmään tai sen viereen ja merkitä ”Säästöpuuryhmä”. Sama koskisi myös esimerkiksi riistatiheiköitä sekä pistemäisiä monimuotoisuusluontokohteita, esimerkiksi pysty- ja maalahopuita puunkorjuutyömaalla tai tekopökkelöitä, joista latva jätetään maahan hakkuussa. Tätä käytäntöä ei kuitenkaan voida toteuttaa runkokoodilla, vaan on käytännön toteutusta varten on rakennettava ja standardoitava uudet käytännöt.

On huomioitava, että lähivuosina käytettävä hakkuukoneenkuljettajan tekemä runkokoodikirjaukset ja hakkuulaitteen tarkentuva sijaintitieto tarjoavat mahdollisuuksia monimuotoisuuden dokumentointiin hakkuissa, mutta tuovat osin samalla lisätöitä hakkuukoneenkuljettajalle. Tavoitteena onkin oltava automatisoitu metsäluonnon monimuotoisuuden mittaaminen ja dokumentointi (vrt. Ovaskainen ym.

2019). Automatisoitu monimuotoisuuden mittaaminen ja dokumentointi edellyttää, että hakkuukoneeseen tuodaan sensori (esimerkiksi laserkeilain ja/tai konenäkö, vrt. Ponsse-harvennusavustin-tuotekonsepti), jolla monimuotoisuusindikaattoreista tuotetaan tarkkaa tietoa esimerkiksi säästöpuuryhmän puiden sijainneista, puulajeista, rinnankorkeusläpimitoista, pituuksista ja lukumäärästä, tai toisaalta pystylahopuilla samoista ominaisuustiedoista. Metsäkoneessa olevilla sensoreilla mitattuna haasteellisempia kohteita voivat olla lumen alla olevat maalahopuut talviaikaisissa hakkuissa.

Metsäkoneiden paikannuksen apuna voidaan käyttää myös olemassa olevaa puustokarttaa. Metsäkoneen paikantaminen suhteessa lähialueen puihin (Hyyppä ym. 2021) voi tuottaa varsin tarkkaa sijaintitietoa hakkuussa. Puukartan sovitus voi olla manuaalinen tai automaattinen. Yksinpuinkartta ja tarkka paikannus millä tahansa tekniikalla mahdollistaisi myös reaaliaikaisen puustotulkinnan ja monimuotoisuustiedon keräämisen.

Voidaan arvioida, että tarkan (esimerkiksi pystylahopuulla puulaji, rinnankorkeusläpimitta, pituus ja sijainti) ja automatisoidun tiedon tuottamisen kehittäminen metsäkoneessa olevilla sensoreilla kestää vielä vuosia, mutta on mahdollista tällä vuosikymmenellä. Tulee myös huomioida, että jos metsäkoneissa on monia itsenäisesti toimivia sensorijärjestelmiä, niiden aikajärjestelmien tulee olla synkronisoituja keskenään. Nopeasti liikkuva puomi ja systemaattiset virheet aikamittausten välillä voivat tuottaa helposti useiden metrien virheitä paikannuksessa.

Tulevaisuuden visiona on oltava, että metsäluonnon monimuotoisuuden mittaaminen ja dokumentointi tuotetaan puunkorjuukoneilla siltä osin kuin se on kustannustehokasta verrattuna kaukokartoitusmenetelmiin (kuva 1). Jatkossa tarkalla paikka- ja sensoritiedolla voidaan esimerkiksi välttää vahingossa hakkaamasta metsälain 10 §:n erityisen tärkeitä elinympäristöjä. Mittaamisen ja dokumentoinnin lisäksi jatkossa metsäkonetiedolla ja kehittyneellä sensorijärjestelmällä voidaan niin ikään ohjeistaa ja muistuttaa hakkuukoneenkuljettajaa jättämään hakkuussa säästöpuuryhmiä, suuria lehtipuita, lahopuuta ja riistatiheiköitä sekä tekemään tekopötkelöitä. Sensorijärjestelmä voi myös varoittaa kuljettajaa ajamasta maalahopuiden ylitse puunkorjuussa. Tämä kaikki tukee tavoitteita biologisen monimuotoisuuden ja ekosysteemien suojelusta sekä tehtyjen toimenpiteiden todentamisesta ja dokumentoinnista.



Kuva 1. Tulevaisuuden visio, miten hakkuukoneenkuljettajaa voidaan avustaa ja tukea poistettavien ja toisaalta säästettävien puiden valinnassa tai jopa automatisoida täysin niiden valinta. Lähde: Komatsu Forest Oy.

3 Kirjallisuus

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>

Hell M, Brandmeier M, Briechle S, Krzystek P (2022) Classification of Tree Species and Standing Dead Trees with Lidar Point Clouds Using Two Deep Neural Networks: PointCNN and 3DmFV-Net. *PFG* 90: 103–121. <https://doi.org/10.1007/s41064-022-00200-4>

Hemmerling J, Pflugmacher D, Hostert P (2021) Mapping temperate forest tree species using dense Sentinel-2 time series. *Remote Sens Environ* 267, article id 112743. <https://doi.org/10.1016/j.rse.2021.112743>

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>

Hyyppä E, Muhojoki J, Yu X, Kukko A, Kaartinen H, Hyyppä J (2021) Efficient coarse registration method using translation- and rotation-invariant local descriptors towards fully automated forest inventory. *ISPRS Open J Photogr Remote Sens* 2, article id 100007. <https://doi.org/10.1016/j.ophoto.2021.100007>

Kaartinen H ym. (2024) Metsäkoneen paikannustetit FGI-Luke-UEF 2021-2022. Käsikirjoitus.

Kacic P, Kuenzer C (2022) Forest Biodiversity Monitoring Based on Remotely Sensed Spectral Diversity—A Review. *Remote Sens* 14, article id 5363. <https://doi.org/10.3390/rs14215363>

Kattenborn T, Eichel J, Fassnacht FE (2019) Convolutional Neural Networks enable efficient, accurate and fine-grained segmentation of plant species and communities from high-resolution UAV imagery. *Sci Rep* 9, article id 17656. <https://doi.org/10.1038/s41598-019-53797-9>

Kukkonen M, Korhonen L, Maltamo M, Suvanto A, Packalen P (2018) How much can airborne laser scanning based forest inventory by tree species benefit from auxiliary optical data? *Int J Appl Earth Obs Geoinf* 72: 91–98. <https://doi.org/10.1016/j.jag.2018.06.017>

Li S, Brandt M, Fensholt R, Kariryaa A, Igel C, Gieseke F, Nord-Larsen T, Oehmcke S, Carlsen AH, Junttila S, Tong X, d’Aspremont A, Ciais P (2023) Deep learning enables image-based tree counting, crown segmentation, and height prediction at national scale. *PNAS Nexus* 2, article id pgad076. <https://doi.org/10.1093/pnasnexus/pgad076>

Ovaskainen H (toim) (2019) Kohti automaattista puunkorjuun laadun mittaamista. *Metsätehon raportti* 251. 51 s.

Perrone M, Di Febbraro M, Conti L, Divišek J, Chytrý M, Keil P, Carranza ML, Rocchini D, Torresani M, Moudrý V, Šimová P, Prajzlerová D, Müllerová J, Wild J, Malavasi M (2023) The relationship between spectral and plant diversity: Disentangling the influence of metrics and habitat types at the landscape scale. *Remote Sens Environ* 293, article id 113591. <https://doi.org/10.1016/j.rse.2023.113591>

Persson M, Lindberg E, Reese H (2018) Tree Species Classification with Multi-Temporal Sentinel-2 Data. *Remote Sens* 10, article id 1794. <https://doi.org/10.3390/rs10111794>

Puliti S, McLean JP, Cattaneo N, Fischer C, Astrup R (2023) Tree height-growth trajectory estimation using uni-temporal UAV laser scanning data and deep learning. *Forestry* 96 :37–48.

<https://doi.org/10.1093/forestry/cpac026>

Rautiainen M, Hovi A, Kuusinen N, Juola J, Forsström P, Salko S-S, Schraik D, Burdun I (2022) Avoimia spektrikirjastoja Suomen metsistä. *Metsätieteen aikakauskirja* artikkelitunnus 10734.

<https://doi.org/10.14214/ma.10734>

Rossi C, Kneubühler M, Schütz M, Schaepman ME, Haller RM, Risch AC (2021) Remote sensing of spectral diversity: A new methodological approach to account for spatio-temporal dissimilarities between plant communities. *Ecol Ind* 130, article id 108106. <https://doi.org/10.1016/j.ecolind.2021.108106>

Schweiger AK, Cavender-Bares J, Townsend PA, Hobbie SE, Madritch MD, Wang R, Tilman D, Gamon JA (2018) Plant spectral diversity integrates functional and phylogenetic components of biodiversity and predicts ecosystem function. *Nat Ecol Evol* 2: 976–982. <https://doi.org/10.1038/s41559-018-0551-1>