

Luonnonmukainen täsmäpuuhakkuu (LUOMUHAKKUU)

LOPPURAPORTTI 28.11.2024

LUOMUHAKKUU.fi 



Euroopan unionin
rahoittama
NextGenerationEU

**Helsingin yliopisto
Arbonaut Oy
Tampereen seudun ammattiopisto (TREDU)
yrittäjäyhteistyökumppanit**

Sisällysluettelo

1	Hankkeen esittely	3
1.1	Hankkeen tavoitteet	3
1.2	Yhteenveto hankkeesta	3
2	Hankkeen toteutus ja toteutusvaiheen arviointi	3
2.1	Menetelmät ja aineisto	3
2.2	Aikataulu ja resurssit (sis. toteutuksen organisaatio ja yhteistyökumppanit)	4
2.3	Kustannukset ja rahoitus	5
2.4	Raportointi, julkaisut ja seuranta	5
2.5	Toteutusvaiheen arviointi	6
2.6	DNSH-kriteerien toteutuminen	6
3	Tulokset ja niiden arviointi	7
3.1	Tulosten esittely	7
3.1.1	Syväoppimiseen ja drone-inventointiin pohjautuvat puukohtaiset kartat kohdealueille	7
3.1.2	Menetelmät erikoispuiden (kookkaat puut, lahoppuut, jne) löytämiseksi ja huomioon ottamiseksi puunkorjuussa (Arbonaut)	9
3.1.3	Kokemukset opetushenkilöstöltä maasto- ja simulaattorit työskentelystä uusien karttatietojen avulla	11
3.1.4	Maaperänäytteiden analyysit metsikkökoealojen raekokojakauman selvittämiseksi	12
3.1.5	Koneoppimiseen pohjautuva malli hienojakoisten maalajien ennustamiseksi Parkanon tuotantoalueelle	12
3.1.6	Monitavoitteinen puunvalinta harvennushakkuussa	14
3.1.7	Syväoppimiseen pohjautuva malli vanhojen ajourien mallintamiseksi ja visualisoimiseksi karttatasoksi	15
3.1.8	Algoritmikonaisuus ajouran keskiviivan sekä metsäkoneiden ajokertojen määrittämiseksi	15
3.1.9	Metsikön puusto- ja maastotiedon jatkojalostus metsikön digitaalisen kaksosiksi simulaattorikoulutusta varten (alihankinta Creanex Oy)	17
3.1.10	Metsän digitaaliseen kaksoseen pohjautuva metsäkoneen simulaattorikoulutuksen oppimisympäristö	17
4	Hankkeen päätulokset ja toimenpidesuosituksset	22

1 Hankkeen esittely

1.1 Hankkeen tavoitteet

LUOMUHAKKUU-projektin tavoitteena on kehittää, testata ja jalkauttaa käytäntöön joukko menetelmiä, joiden avulla metsäalan käytännön toimijat voivat toteuttaa luonnonmukaista täsmäpuukorjuuta. Luonnonmukaisella täsmäpuukorjuulla tarkoitetaan puunkorjuuoperaatiota, joka ottaa huomioon luonnon omat erityispiirteet ja jossa päätöksenteko puuvalinnasta ja metsänkäsittelymenetelmästä tehdään mikrokuviotasolla. Projektin tuloksena syntyy älykkäisiin analysointimenetelmiin pohjautuva menetelmäkokonaisuus, joiden avulla metsikön kasvupotentiaalia, hiilensidontakykyä, biodiversiteettiarvoa sekä puunkorjuuoperaation mahdollisia haittavaikutuksia voidaan tarkastella kokonaisuutena.

1.2 Yhteenveto hankkeesta

LUOMUHAKKUU-projektin tavoitteena on kehittää, testata ja jalkauttaa käytäntöön joukko menetelmiä, joiden avulla metsäalan käytännön toimijat voivat toteuttaa luonnonmukaista täsmäpuukorjuuta. Projektin ovat toteuttaneet Helsingin yliopisto (vastuuhenkilö prof. Jori Uusitalo), Tampereen seudun ammattiopisto (TREDU) (vastuuhenkilö Janne Ruokonen) ja Arbonaut Oy (vastuuhenkilö Vesa Leppänen). Lisäksi Ponsse on osallistunut projektiin omalla rahoituksella. Hankkeen kokonaisbudjetti vuosille 2022-24 on 1 125 357 €, josta MMM:ltä haettava osuus on 787 700€ (70%).

Hankkeen aikana on saavutettu merkittävä digiloikka kohti täsmäpuukorjuuta. Tämä tarkoittaa, että metsän kasvatuksen, ympäristönäkökulmien ja metsäoperaatioiden toteutuksen kannalta olennaiset metsän rakennepiirteet ennustetaan kaukokartoitukseen pohjautuvien mallien avulla ja tämä tieto tuodaan puunkorjuun toteuttajien avuksi operaatiota toteutettaessa. Hankkeen päätulokset ovat:

- Metsikön puut voidaan tehokkaimmin tunnistaa kaukokartoitusdatan avulla yhdistelemällä eri datalähteitä (laser, ilmakehäkuva ja vääräväri) ja hyödyntämällä syväoppimisista
- Metsikön maalajit voidaan nykyistä paremmin tunnistaa mikrokuviotasolla käyttämällä modernin digitaalisen maamallinnuksen tekniikoita (digital soil mapping). Hienojakoisia maalajeja selittävät parhaiten topografiatunnukset ja satelliittidatasta johdetut kasvillisuusindeksit.
- Edellisessä puunkorjuuoperaatiossa syntynyttä tietoa ajouraverkostosta (kaukokartoituspohjainen tulkinta tai metsäkoneen reitinjäljitystieto) voidaan tulevaisuudessa käyttää monipuolisesti hyödyksi hakkuukohteen ajouraverkoston suunnittelussa
- Metsän digitaaliseen kaksoseen pohjautuva metsäkoneen simulaattorikoulutuksen oppimisympäristö luo mahdollisuuden opettaa ilmastokestävää metsänhoitoa metsäkoneen kuljettajille.

Hankkeen aikana on syntynyt 16 julkaisua (3 tieteellistä julkaisua, 10 konferenssiesitelmää, 1 podcast, 2 tieteellisessä vertaisarvioinnissa olevaa käsikirjoitusta). Tämän lisäksi ainakin 4 käsikirjoitusta lähetetään vuonna 2025 tieteelliseen vertaisarviointiin. Hankkeen tutkimustuloksia esitellään osoitteessa <https://luomuhakkuu.fi>.

2 Hankkeen toteutus ja toteutusvaiheen arviointi

2.1 Menetelmät ja aineisto

Hankkeessa on kerätty erittäin laaja tutkimusaineistokokonaisuus, joka käsittää

- Koemetsiköiden mittaukset ja erilliskannaukset
 - o Koemetsiköt ovat hankittu yhteistyökumppaneiden metsäalueilta Parkanon, Ikaalisen, Ähtärin, Soinin, Padasjoen sekä Äänekosken alueilta
 - o 17 koeleimikon maastomittaukset, skannaukset dronella (Lidar resoluutio 100 p/m², RGB ja vääräväri: pikselin resoluutio 5cm) sekä mittaukset yliopiston maastolaserkeilauslaitteella (TLS)

- Vanhojen puunkorjuukohteiden ajourasyvyyksien inventointi sekä maanäytteiden kerääminen
- Metsäkoneiden keräämän paikannustiedon hankinta yhteistyökumppaneilta
- Julkisen metsävaratiedon hankinta kohdealueilta (Lidar resoluutio 5 p/m², RGB ja vääräväri: pikselin resoluutio 50 cm)
- Suomen Metsäkeskuksen vuonna 2023 mitaamat puukartat 462 koekohteelta

Aineistojen prosessointiin ovat osallistuneet kaikki toteuttajat. Suurin vastuu on ollut HY:lla. Olemme hankkeen aikana analysoineet ja jatkojalostanut seuraavat kokonaisuudet:

- Syväoppimiseen ja drone-inventointiin pohjautuvat puukohtaiset kartat kohdealueille
- Menetelmät erikoispuiden (kookkaat puut, lahoppuut, jne) löytämiseksi ja huomioon ottamiseksi puunkorjuussa
- Maaperänäytteiden analyysit maaperän raekokojakauman selvittämiseksi
- Koneoppimiseen pohjautuva malli hienojakoisten maalajien ennustamiseksi Parkanon tuotantoalueelle
- Monitavoitteinen puuvalinnan optimointi kasvatushakkuussa
- Syväoppimiseen pohjautuva malli vanhojen ajourien mallintamiseksi ja visualisoimiseksi karttatasoilla
- ArcGIS ja Python -työkaluihin pohjautuva algoritmikokonaisuus, jolla voidaan hakkuun jälkeen määrittää metsäkoneiden käyttämän ajourareitistön keskiviiva sekä metsäkoneiden ajokerrat kullakin ajouraverkoston segmentillä.
- Konedatan tuottaman API- aineiston räätälöinti tutkimuskäyttöön (TREDU/ Ponsse)
- Metsikön puusto- ja maastotiedon jatkojalostus metsikön digitaaliseksi kaksosiksi simulaattorikoulutusta varten (alihankinta Creanex Oy)
- Hakkuukoneen simulaattoriympäristön kehittäminen uudelleenlaiseksi opetusympäristöksi
- Uuden opetuskokonaisuuden rakentaminen simulaattoriympäristöön, jolla opetetaan ilmastoystävällisempää ja monimuotoisempaa metsänhoitoa
- Simulaattoritehtävät reunametsien- ja eroosioherkkien rinteiden käsittelyyn sekä peitteisen metsätalouden kokonaisvaltainen oppikokonaisuus, jossa huomioidaan myös pohjaveden pinnan korkeuden säätely sekä hallittu varjostus puuston avulla
- Kehitettiin kuljettajaa opastavien karttatasojen käyttöön liittyvä oppimateriaali

Hankkeessa on myös aktiivisesti pyritty jalkauttamaan tutkimustuloksia käytäntöön. Tähän kokonaisuuteen kuuluvat

- Koneellisen hakkuun simulaattoriopetukseen rakennetun uuden opetuskokonaisuuden siirto ja käyttöönotto muille metsäkonekouluille
- Hankkeen aktiivinen viestintä tiedotteiden ja nettisivupäivitysten avulla (alihankinta Suomen Metsäviestintä Oy)
- Väliseminaari 15.11. 2023 TREDUn Metsätien toimipisteessä ja loppuseminaari Metsäpäivillä 24.-26.11.2024
- Hanketta esiteltiin myös kansainvälisessä lisätyn todellisuuden tapahtumassa AWE EU 2024-messuilla Itävallan Wienissä

Hankkeen toteutus sujui erinomaisesti. Yhteistyö eri toimijoiden välillä oli sujuvaa.

2.2 Aikataulu ja resurssit (sis. toteutuksen organisaatio ja yhteistyökumppanit)

Helsingin yliopisto on vastannut pääosin aineistojen keräämisestä. Arbonaut on myös hankkinut omiin tutkimustarpeisiinsa tutkimusaineistoja. Tutkimusaineistojen analyysiin ovat osallistuneet kaikki partnerit. Olemme saaneet kerättyä tutkimusaineistoja yhteistyökumppaneiden metsäkohteilta (Metsähallitus, Finsilva, Metsä Group). Heiltä saatu neuvonta ja avunanto ovat olleet korvaamatonta tavoitteiden saavuttamiseksi. Projektin kannalta tärkeät osavaiheet, joita ei itse pystytty toteuttamaan, ostettiin ostopalveluna (drone-skannaukset/Carelian Forest Consulting Oy ja simulaattoriympäristön räätälöinti/Creanex Oy). Projektin

viestintää on koordinoanut Suomen Metsäviestintä Oy. Heidän tehtävänä on ollut tiedotteiden laadinta sekä hankkeen tulosten julkaiseminen hankkeen omilla nettisivuilla (Luomuhakkuu.fi).

2.3 Kustannukset ja rahoitus

Projektille myönnetty rahoitus on kaikissa organisaatiossa käytetty täysmääräisenä. Viimeinen maksatuserä kaikilta kolmelta rahoituksen saajalta (Helsingin yliopisto, Tredu ja Arbonaut) esitetään hyväksyttäväksi hankkeen ohjausryhmän kokouksessa 28.11.2024. Hankkeen toteutuneet kustannukset ja vertailu budjettiin toimijoittain on esitetty alla olevassa taulukossa. Luvut sisältävät edellisissä maksatushakemuksissa hyväksytyt kustannukset sekä viimeisessä maksuerässä haettavat kustannukset.

	Budjetti (€)	Toteuma (€)	Tulos (€)
Helsingin yliopisto	804857	809 767	-4901
Arbonaut Oy	201 000	202 439	-1439
Tredu	119500	120907	-1407
Yhteensä	1125357	1133113	-7747

Rahoituspäätöksen mukaisesti rahoitus jakautuu eri toimijoiden suhteen seuraavasti:

	MMM (€)	Oma rah. (€)	Yhteensä (€)
Helsingin yliopisto	563400	241457	804857
Arbonaut Oy	140700	60300	200100
Tredu	83600	35850	119500
Yhteensä	787700	337607	1125357

2.4 Raportointi, julkaisu ja seuranta

Projektin aikana on julkaistu seuraavat raportit ja julkaisut:

Tieteelliset julkaisut:

- Abdi O, Uusitalo J, Kivinen V.-P. 2022. Logging Trail Segmentation via a Novel U-Net Convolutional Neural Network and High-Density Laser Scanning Data. Remote Sens. 2022, 14, 349. <https://doi.org/10.3390/rs14020349>
- Abdi O, Uusitalo J, Pietarinen J, Lajunen A. 2022. Evaluation of Forest Features Determining GNSS Positioning Accuracy of a Novel Low-Cost, Mobile RTK System Using LiDAR and TreeNet. Remote Sensing. 2022, 14(12):2856. <https://doi.org/10.3390/rs14122856>
- Holmström E, Nikander J, Backman J, Väättäinen K, Uusitalo J & Jylhä P. 2022. A multi-objective optimization strategy for timber forwarding in cut-to-length harvesting operations, International Journal of Forest Engineering. <https://doi.org/10.1080/14942119.2022.2149003>

Konferenssiesitelmät:

- Uusitalo J, Abdi O, Kivinen VP, Laamanen V, Ruokonen J. 2023. Assessing the feasibility of using super high-resolution forest environment maps in harvesting simulators for precision harvesting applications. FORMEC Conference. Florence, Italy, September 20-23, 2023.
- Abdi O, Uusitalo J, Kivinen VP, Laamanen V. 2023. Detecting and visualizing old logging trails for upcoming thinning operations. FORMEC Conference. Florence, Italy, September 20-23, 2023.
- Uusitalo J, Omid A, Kivinen VP. 2022. Detection of Old Logging Trails - The Initial Step to Solve the Logging Trail Network Design Problem. 2022 COFE-FORMEC- IUFRO Division 3 joint meeting. Corvallis, Oregon, USA. Oct 4-7, 2022.
- Uusitalo J, Abdi O, Koivukoski K, Cao S. 2024. Consolidation of forest machine GNSS tracks into one solid logging trail line. FORMEC 2024 Conference. Gdansk, Poland, June 11-14, 2024.
- Abdi O, Laamanen V, Uusitalo J, Kivinen VP. 2024. Fine-grained Soil Particles Prediction Based on GeoAI and LiDAR for Precision Harvesting Applications. IUFRO 2024 Conference. Stockholm, Sweden, June 23-29, 2024.
- Niemi M.T., Vauhkonen J, Uusitalo J. 2024. How tree selection affects ecosystem, service trade-offs and synergies in boreal forest thinning? IUFRO 2024 Conference. Stockholm, Sweden, June 23-29, 2024.

Leppänen V. 2024. ERITYISPUIDEN TUNNISTAMINEN HAKKUUKONEEN KULJETTAJAN TUEKSI. Metsäpäivät Conference. Helsinki, Finland. October 24-25, 2024.

Uusitalo J & Niemi M.T. Kohti Luonnonmukaista täsmäpuukorjuuta. Metsäpäivät Conference. Helsinki, Finland. October 24-25, 2024.

Ruokonen Janne. 2024 Luonnonmukaista täsmäpuuhakkuuta digitaalisen kaksosen avulla. Metsäpäivät Conference and fair. Helsinki, Finland. October 24–26.2024

Jurvanen J & Ruokonen J. 2024 Teaching climate- resilient forestry with a Digital twin. AWE EU 2024 Conference and fair. Wien, Austria. October 29- 30.10.2024

Podcast:

Kopponen, Aleks; Ruokonen Janne.2024 Digitaaliset kaksoset ja VR- simulaattorit metsänhoidon opetuksen tukena.
Podcast: Uudistuva Tampere, August 16, 2024
<https://open.spotify.com/episode/7oOQ2AilyghK5M75oXghkM?si=hLqQGZRESHeRggwLnTucPA>

Projektin tuotoksena on lähetetty seuraavat käsikirjoitukset tarkastusprosessiin

Abdi O; Laamanen V; Uusitalo J. Integrating a Novel GeoAI Framework for Instance Segmentation of Tree Species: A Multi-Sensor Approach with RGB, LiDAR, and Multispectral Data. Information Fusion. [Tieteellisessä vertaisarvioinnissa]

Niemi M.T., Vauhkonen J, Uusitalo J. Trade-off analysis for multi-objective boreal forest thinning. [Tieteellisessä vertaisarvioinnissa]

Seuraavia hankkeen tieteellisiä käsikirjoituksia vielä analysoidaan ja kirjoitetaan yliopiston muun rahoituksen avulla.

Cao S, Abdi O, Koivukoski K, Uusitalo J. Automating the Consolidation of GNSS Logging Tracks in Boreal Forests.

Abdi O, Uusitalo J, Cao S. Novel methods to assess efficiency of the logging trail network. Prediction of fine-grained particles with GeoAI and LiDar.

Uusitalo J, Abdi O, Laamanen V, Ruokonen J, Kivinen VP. Bringing a forest harvester simulator to a new era – the benefits to harvest with a real digital twin.

Abdi O, Uusitalo J, Laamanen V. High-Resolution Mapping of Forest Fine-Grained Soil Particles Using Graph Neural Networks on LiDAR and Sentinel-2 Data.

2.5 Toteutusvaiheen arviointi

Hankkeen toteutuksessa ei ole ollut merkittäviä epäonnistumisia. Kaikki operaatioita ei toki toteutettu alkuperäisen suunnitelman mukaisesti. Päädyimme siihen, että täsmämetsänhoitoon liittyviä karttatasoja ei testata Woodforce-ympäristössä, koska se on metsä- ja puunkorjuuyhtiöiden tuotantoversio. Sen sijaan päädyimme testaamaan uusia karttatasoja simulaattoriympäristössä. Karttatasoja on laajasti testattu simulaattoriympäristössä sekä Ponssen metsäkoneissa.

2.6 DNSH-kriteerien toteutuminen

LUOMUHAKKUU-projekti on tukenut vahvasti Suomen kestävä kasvun ohjelman tavoitteita sekä DNSH-periaatteiden noudattamista metsätaloudessa. Eri kehittämiskohteiden vaikutuksia DNSH-periaatteisiin on arvioitu taulukossa 1.

Taulukko 1. Luomuhakkuu-projektin vaikutukset DNSH-periaatteisiin metsätaloudessa.


Ympäristötavoite	Vaikutus (Edistetään =K; Ei Haittaa=N)	Vaikutuksen kuvaus
Ilmastonmuutoksen hillintä	K	Parempi maalajin tulkinta mahdollistaa hiilen sidonnan lisääntymisen kasvupotentiaalin paremman tulkinnan kautta
Ilmastonmuutokseen sopeutuminen	K	Parempi maalajin, kasvuolosuhteiden ja puulajin tulkinta antaa paremmat mahdollisuudet valita kohteelle sopiva puulaji
Vesivarojen ja merten luonnonvarojen kestävä käyttö ja suojelu	K	Parempi kasvuolosuhteiden ja maalajin tulkinta hillitsee vesistövaikutuksia ehkäisemällä korjuuvaurioiden syntyä
Siirtyminen kiertotalouteen	N	Ei merkittävää vaikutusta
Ympäristön pilaantumisen ehkäiseminen ja vähentäminen	K	Parempi kasvuolosuhteiden ja maalajin tulkinta vähentää puunkorjuun ympäristövaikutuksia tehostamalla korjuuoperaation käytännön toteutusta (polttoainekulutus, hiilidioksidipäästöt)
Biologisen monimuotoisuuden ja ekosysteemien suojelu ja ennallistaminen	K	Laho- ja maapuiden ja kookkaiden puuyksilöiden tunnistaminen parantaa biodiversiteettiarvojen huomioonottamista

3 Tulokset ja niiden arviointi

3.1 Tulosten esittely

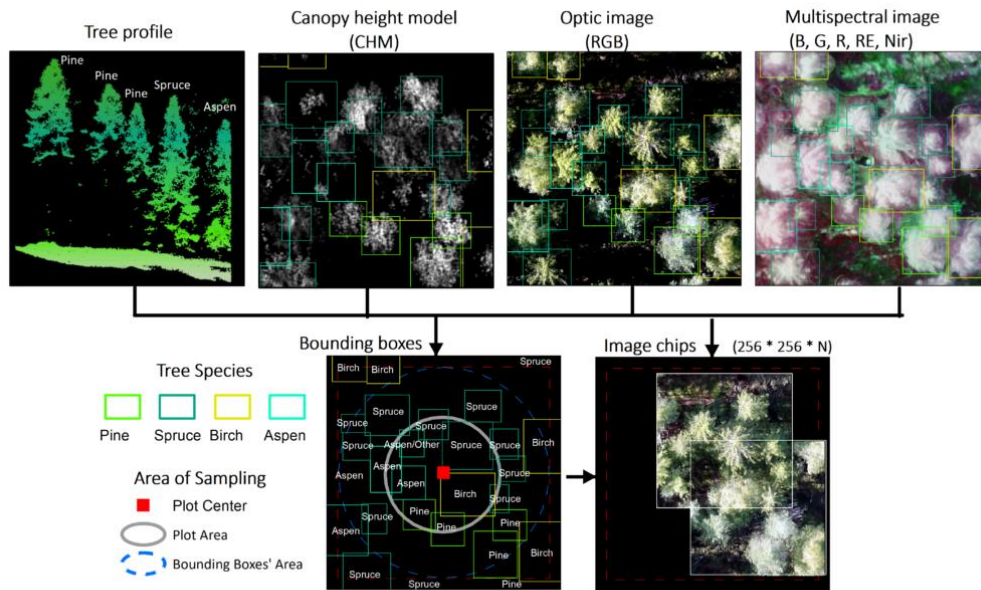
3.1.1 Syväoppimiseen ja drone-inventointiin pohjautuvat puukohtaiset kartat kohdealueille

HYn tutkimusryhmä on tehnyt merkittävän teknologiahyppäyksen yksittäisen puun tulkinnassa yhdistelemällä useita eri data-aineistoja sekä käyttämällä syväoppimisen tekniikkaa. Olemme käyttäneet laskennan pohjana parhaita mahdollisia aineistoja: dronella kuvattuja tiheäpulsisia laserkeilausaineistoja, korkean resoluution RGB- ja vääräväri- kuva-aineistoja. Kehitetyt syväoppimismallit erottavat puujoukosta yksittäisen puun ääriviivat sekä tunnistavat ko. kohteen puulajin (kuva 1).



Kuva 1. Puukohtaisessa tulkinnassa erotetaan yksittäisen puun latva ja tunnistetaan puulaji. Kuva: Omid Abdi

Syväoppimismallit on opetettu mittavan opetusaineiston avulla. Tämä aineisto käsittää lähes 7000 erillistä 256*256 pikselin opetuskoealuruutua, joista on tunnistettu keskimäärin 23 puuta per ruutu. Osa puista on tunnistettu maastossa ja toinen osa laserkeilausprofiilin avulla (kuva 2).



Kuva 2. Syväoppiminen perustuu laajaan opetusaineistoon. Yksittäisen puun puulajin tulkintaan käytetään monipuolisesti eri data-aineistoja Kuva: Omid Abdi.

Syväoppimismallin opettaminen, joka käsittää parhaimmillaan jopa viisi eri data-aineistoa (laser, R, G, B ja vääräväri) vaatii valtavasti laskentatehoa. Olemme käyttäneet laskentaan Tieteellisen laskennan (CSC Oy) supertietokonetta. Opetettujen mallien käyttöön ei sen sijaan tarvita supertietokonetta. Laskenta voidaan toteuttaa tavallisella tai mieluummin grafiikkaprosessorilla (GPU) varustetulla tietokoneella. Mallin avulla voimme tuottaa puukohtaisen tulkinnan metsiköihin, jotka ovat inventoitu samanlaiselle resoluutiolla kuin opetusaineisto (kuva 3).



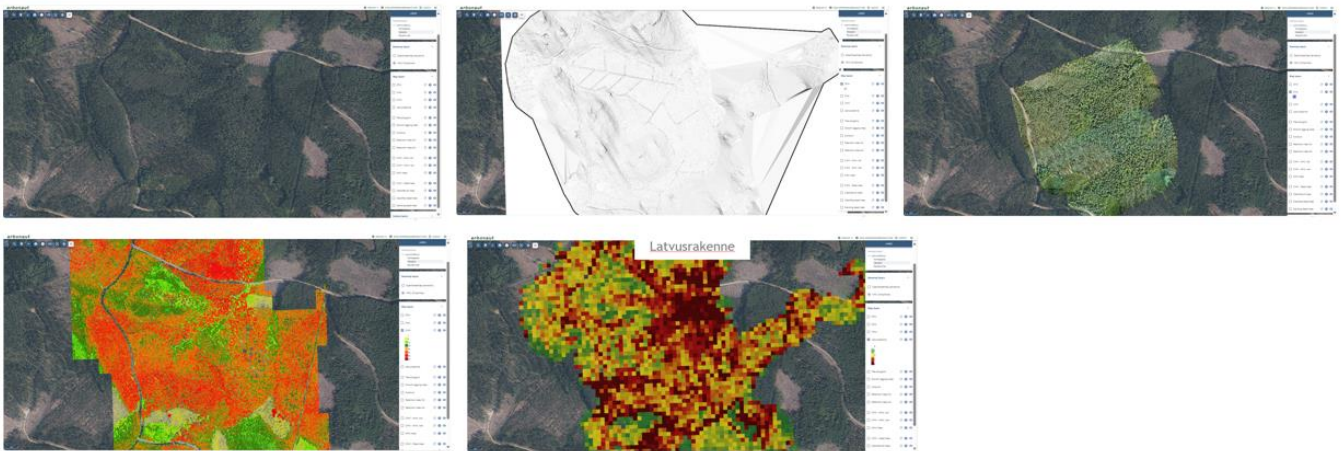
Kuva 3. Laadittujen syväoppimismallien avulla voimme tulkita metsikön kaikkien puiden puulajit sekä niiden tarkat sijainnit. Tulkinnan tarkkuus on noin 80–90%. Kuva: Omid Abdi.

3.1.2 Menetelmät erikoispuiden (kookkaat puut, lahoppuut, jne) löytämiseksi ja huomioon ottamiseksi puunkorjuussa (Arbonaut)

Työpaketin tavoitteena oli tunnistaa ja mahdollisesti mitata erityisiä puuyksilöitä, jotka tulisi huomioida hakkuussa. Tämä tieto hakkuukoneenkuljettajan päätöksenteon tueksi tulee lisäksi tarjota sellaisessa formaatissa, että se auttaa työn suorittamisessa eikä lisää informaatiokuormaa. Tunnistettavia erityispuuita ovat:

- Ympäristöään pidemmät puut
- Etukasvuiset ja huonolaatuiset puut (nk. susipuut)
- Kasvultaan jälkeen jääneet puut ("Hidaskasvuiset puut")
- Kuolleet pystypuut
- Kuolleet maapuut
- Edellisen puusukupolven puut ("Vanhat puut")

Kuvassa 4 on havainnollistettuna lähtöaineiston kokonaisuus.



Kuva 4. Vesijaon tutkimuskohteen havainnointi eri karttatason avulla (Arbonaut Oy)


Lähtökohdiana puuston tunnistamiselle oli, että kaikki puuston latvukset tunnistetaan ja polygonisoidaan (kuva 5).




Kuva 5. Latvuspolygonien erottaminen lähtöaineistosta (Arbonaut Oy)

Kuolleiden pystypuiden tunnistaminen voidaan tehdä vain LiDAR-aineistoa käyttämällä tai yhdistämällä kuvan ja LiDARin tulkintaa (Kuva 6.). Tunnistus tehtiin latvapolygonitasolla. Yhdellä LiDAR-aineistolla opetetun mallin soveltuminen toiseen LiDAR-aineistoon on tämänhetkellä menetelmällä vielä epäselvää. Tämän vuoksi asiaa selvitettiin Random Forest –luokittimella. Random Forest –luokittimella on päästy noin 86 % kokonaisluokittelutarkkuuteen, joka on varsin hyvä tulos. Kuolleen puuston tulkintaan tarvittavan ja riittävän opetusaineiston kerääminen on haasteellista. Suomesta ei löydy kovin helposti tällaisia kohteita. Myös ilmakuvien ja LiDAR-aineiston yhteensopivuus tuo omia haasteitaan, jos ilmakuvaa halutaan käyttää toisena

lähtöaineistona tai maastoaineiston puuttuessa opetusaineistona. Tiheä LiDAR-aineisto auttaa tunnistuksessa. Resoluutio on 15-20 p/m² on suositeltavampi, sillä avoimen metsävaratiedon resoluutiolla 5p/m² tunnistustarkkuus jää hieman matalammaksi. Sen avulla löydetään kyllä runsaasti lahoppuuta sisältävät kohteet (kuva 7.).



Kuva 6. Valokuvan ja Lidar aineiston yhdistämisellä tunnistetaan kuolleet pystypuut.



Kuva7. Esimerkkikuva kuolleiden maapuiden tunnistamisesta.

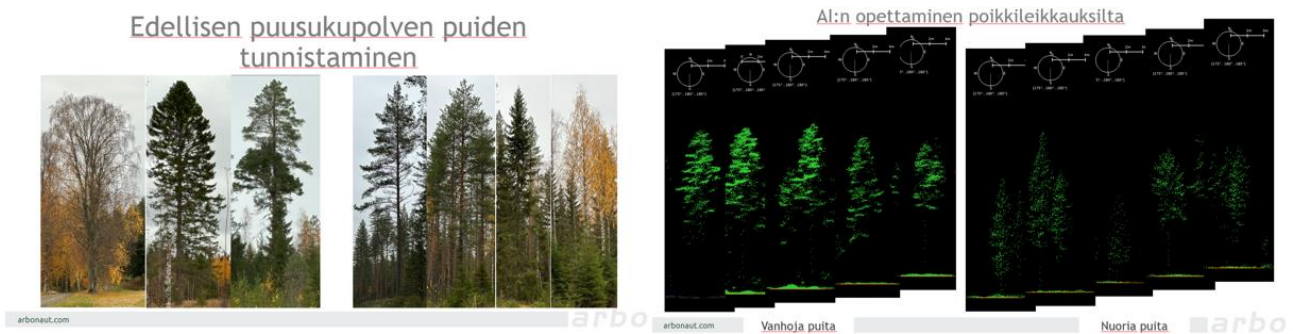


Kuva 8. Esimerkkikuvat Vesijaon tutkimuskohteelta, joissa visualisoidaan ympäristöään pidempiä puita, etukasvuisia puita (nk. susipuut) ja hidaskasvuisia puita.

Edellisen sukupolven puiden tunnistuksessa (kuvassa 8.) käytettiin apuna myös LiDAR aineiston poikkileikkauksia, jotka syötettiin koneoppimisalgoritmeille. Poikkileikkaukset tuotettiin Arbonautin omalla työkalulla, joka tekee annetuille polygoneille (tässä tilanteessa puiden latvuspolygonit) halutun määrän poikkileikkauksia. Nämä poikkileikkaukset poimivat LiDAR aineistosta niihin osuvat pisteet ja toinen työkalu tuottaa poimituista pisteistä kuvatiedoston. Koneoppimisalgoritmina käytettiin YOLOv8-algoritmia, sillä se soveltuu hyvin kuvien luokitteluun ja toimii Python-ympäristössä.

Mallin koulutukseen etsittiin ensin tarpeeksi suuri määrä vanhojen ja nuorien puiden poikkileikkauksia. Aineiston keräämisen jälkeen poikkileikkaukset ja niiden sisällä olevat puut merkattiin oikeilla tunnuksilla (vanha tai nuori kuvassa 9.) ja niiden tarkka sijainti kuvassa määritettiin asettamalla puut rajauslaatikoihin. Tämän jälkeen kuvat syötettiin algoritmeille, joka tuotti valmiin koulutetun mallin. Tämä malli kykenee havaitsemaan opetusaineistona käytettyjen kuvien kaltaisesta aineistosta vanhoja sekä nuoria puita. Lopputuloksena mallin käytössä syntyy poikkileikkauksia, joissa mallin tunnistamat puut ovat rajauslaatikoiden sisällä, ja niistä löytyy myös varmuusarvo (kuinka varma algoritmi on luokittelutuloksesta).

Koulutettua mallia on helppo soveltaa suureenkin aineistoon, sillä yhden kuvan luokitteluun menee vain 10-20ms ja 72 000 kuvan aineiston luokitteluun noin 2 h.




Kuva9. Kuvasarja, jossa havainnollistetaan, kuinka vanhan puun tunnistusta opetetaan tekoälylle.

Puustotunnusten löytämisessä koettiin haasteita. Hankkeen metsistä ei löytynyt riittävästi erityispuiden tunnusmerkkejä täyttäviä puita. Hankkeessa päätettiin, että tarvittaessa haetaan kohteita, joilla on reilummin tunnusmerkkejä täyttäviä puustoa, jotta niitä voidaan käyttää tunnistamisen algoritmeille opetusaineistona. Erityispuiden tunnistamiseksi tehtiin avuksi poikkileikkauksia, joiden perusteella oli helpompaa tunnistaa puunrungon ominaispiirteitä. Poikkileikkauksiin tulee kuitenkin keskellä olevan puun lisäksi muita puita, ja osa niistä tunnistuu mukaan tulkintaan. Mikä puusta on "se oikea", tuli aineistoa tulkittaessa vastaan usein. Joskus sama puu tunnistautuu vanhaksi ja nuoreksi, tosin eri luotettavuudella. Joskus tunnistuu puun latvuksen toinen reuna puuksi, joka täytyi jättää huomioimatta. Kun LiDARin tiheys vaihtelee, aiheuttaa se tulkinnassa epävarmuutta. Harvan lidarin kohdissa tunnistaminen ei useinkaan onnistu, johtuen pistepilven hajanaisuudesta. Samoin LiDARin katselukulma vaikuttaa puun ulkonäköön ja voinee vaikuttaa kyseisen puun tulkintatulokseen. Asiaa kuitenkin auttoi, kun saatiin riittävä määrä opetusaineistoa. Opetusaineistoa jouduttiin etsimään laajalti Suomesta. Tätä työtä tehdessä oli huomioin arvoista se, ettei näitä esimerkkejä löydy kovin helposti, tämä korostui suuresti vanhojen puiden tunnistamisessa. Tätä varten käytettiin lisäksi aineistoa, joka on kerätty Pohjois-Ruotsista. Tämän aineiston avulla tulkinta helpottui ja lopputuloksessa päästiin hyvään tulokseen. Tässä projektissa kaikki vanhat puut puulajista huolimatta tulkittiin vanhoiksi/nuoriksi. Tulevaisuudessa saattaisi olla järkevää kokeilla vanha kuusi / vanha mänty / vanha lehtipuu / nuori kuusi / nuori mänty / nuori lehtipuu –luokittelua.

3.1.3 Kokemukset opetushenkilöstöltä maasto- ja simulaattorit työskentelystä uusien karttatietojen avulla

Tunnistetut erikoispuut auttavat kuljettajia päätöksenteossa. Erikoispuiden tunnistamisen perusteella tieto ja sijainti voidaan tuoda esille ja korostaa kartalle näkyviin. Korostukset koneen kartalle tuotuna auttavat selkeästi työssä tehtäviä päätöksiä. Tieto siitä, ovatko koneen karttanäkymässä esiintyvät puu lahopuu, kuollut puu, etukasvuinen tai heikkokasvuinen, auttaa kuljettajaa tekemään tekemään metsäluonnonhoidon näkökulmasta parempia ratkaisuja. Näin luonnonkannalta tärkeitä tekijöitä voidaan jättää entistä paremmin maastoon. Puustotietojen lisäksi käytössä ollut kulkukelpoisuutta helpottava maaperän kosteus kartta auttaa maastossa liikkumisen lisäksi puulajivalinnassa. Kosteille paikoille on mahdollisuus jättää juuristoltaan vahvempaa puustoa, joka pienentää tuuliturhoriskiä sekä auttaa myös lehtipuuston kasvuun jättämisen lisäämisessä.



Kuva 10. Esimerkkikuvia puustotietojen esittämisestä hakkuukoneen karttanäkymässä tukemaan kuljettajan päätöksentekoa.

3.1.4 Maaperänäytteiden analyysit metsikkökoealojen raekokojakauman selvittämiseksi

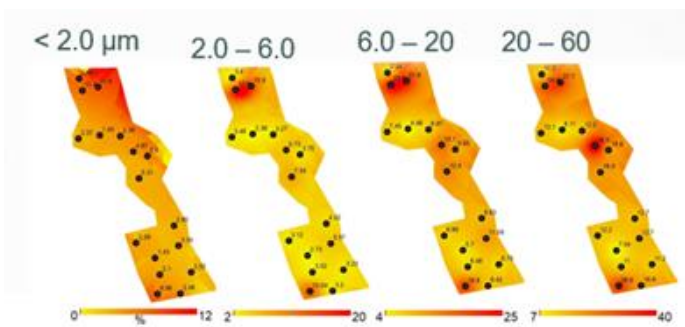
Keräsimme vuonna 2022 maaperänäytteitä maaperäkairalla 332 metsikkökoealalta (47 metsikkökuviota). Maaperänäytteet analysoitiin loppuvuonna 2022 Helsingin yliopiston metsätieteen osaston laitteistoilla seuraavasti:

- Maaperänäytteiden kuivaus ja seulonta silmäkooltaan 2 ja 0,6 mm seulalla karkeiden jakeiden osuuden määrittämiseksi.
- Maaperänäytteiden orgaanisen aineen pitoisuuden määrittäminen hehkutusmenetelmällä
- Lämpimältä alle 0,6 mm jakeiden lajitekoostumuksen määrittäminen laserdiffraktiomenetelmällä
- Laserdiffraktiomenetelmän ja perinteisen areometrisen menetelmän vertailu - referenssinäytteiden valmistelu sekä hankinta ostopalveluna

Jokaisen metsikkökoealan sijainti määriteltiin tarkkuuspaikantimen avulla (RTK/GNSS). Maaperänäytekokonaisuus on hyvin arvokas ja sitä voidaan käyttää maaperämallinnuksen pohjana.


3.1.5 Koneoppimiseen pohjautuva malli hienojakoisten maalajien ennustamiseksi Parkanon tuotantoalueelle

Opetusaineistona käytimme hankkeessa kerättyä 330 kpl maalajinäytekokonaisuutta. Ensimmäisessä vaiheessa interpoloimme maalajinäytteistä saadut mitta-arvot yli koko koemetsikön siten, että jokaiselle metsikön pisteelle lasketaan eri maalajien osuudet (kuva 11).




Kuva 11. Raekokoluokkien (<2.0 μm = savi; 2.0-6.0 μm = hieno siltti; 6.0-20 μm = keskisiltti; 20-60 μm = karkea siltti) osuudet kohdistetaan metsikön jokaiseen pisteeseen geotilastollisen co-kringing-menetelmän avulla

Koemetsiköiden jokaiseen pisteeseen tehtiin avoimeen metsävaratietoon pohjautuva (Laserkeilaus, RGB ja Vääräväri) puulajitunnistus. Tässä on käytetty Luomuhakkuu-hankkeen yksinpuintulkinta-tehtävää varten hankittua koeleimikkoaineistoa opetusaineistona. Puulajitunnistuksen pohjalta segmentoitiin kukin metsikkö sopiviksi lohkoiksi (noin 10 x 10 m) (kuva 12).



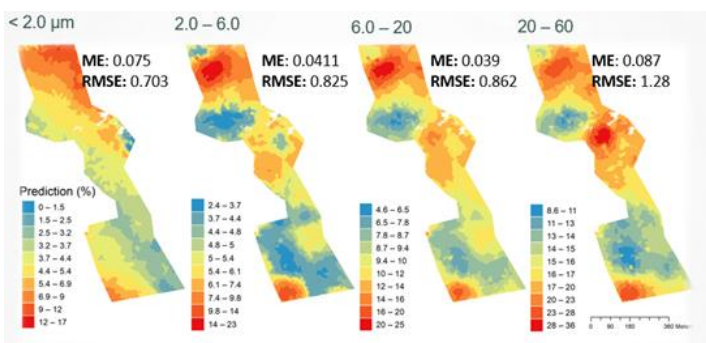
Kuva 12. Metsikkö segmentoidaan lohkoiksi puulajiryhmittymien pohjalta.

Kuhunkin lohkoon laskettiin kymmeniä erilaisia avoimeen metsävaratietoon ja satelliittitietoon pohjautuvia topografia- ja kasvillisuustietoparametrejä. Eri parametrien selitysvoima selvitettiin koneoppimisen avulla. Lopputulos osoittaa (kuva 12), että topografiatiedot (erityisesti korkeus merenpinnasta sekä suhteellisesti alavat kohdat) selittävät maalajia parhaiten (yhteensä >50%). Näiden lisäksi satelliittitietoon pohjautuvilla kasvillisuusindekseillä on vahva selitysvoima (>25%).



Kuva 13. Eri muuttujien merkitsevyys raekokoluokittain. Keltainen väri = laserkeilausdatasta johdetut topografiatunnukset; sininen väri = laserkeilausdatasta johdettu hydrologiatunnukset; violetti väri = Satelliittidatasta johdetut kasvillisuusindeksit; vihreä väri = avoimesta metsävaratiedosta johdetut puustotunnukset.

Menetelmä on lupaava ja sen kehittämiseksi tarvitaan lisää kehitystyötä ja parempia aineistoja. Länsi-Suomen alueella päästiin tällä menetelmällä yli 80 % selitysasteisiin ja pieniin keskivirheisiin maalajiosuuksien ennustamisessa (kuva 14).




Kuva 14. Esimerkki maalajikartasta yhdessä metsikössä. Raekokoluokat ovat (<2.0 µm = savi; 2.0-6.0 µm = hieno siltti; 6.0-20 µm = keskisiltti; 20-60 µm = karkea siltti).

3.1.6 Monitavoitteinen puunvalinta harvennushakkuussa

Kasvatushakkuun suunnittelu ja toteutus vaikuttavat merkittävästi sekä metsätalouden kannattavuuteen että muihin metsän tarjoamiin aineellisiin ja aineettomiin hyötyihin, ns. ekosysteemipalveluihin. Puukartan avulla kasvatushakkuussa poistettavien puiden valinta voidaan optimoida metsänomistajan tavoitteiden mukaan. Kasvatushakkuussa osa metsään sitoutuneesta pääomasta realisoituu myyntituloina metsänomistajalle, minkä lisäksi harvennus lisää jäljelle jäävien puiden kasvuresursseja ja vaikuttaa muun muassa metsän rakenteeseen, monimuotoisuuteen, maisemaan sekä hiilinieluun ja -varastoon. Puutason metsävaratiedon tarkkuus ja saatavuus ovat parantuneet nopeasti, mikä mahdollistaa poistettavien puiden valinnan optimoinnin etukäteen metsän rakennevaihtelu ja metsänomistajan tavoitteet huomioiden.

Luomuhakkuu-hankkeessa testattiin koealatasolla, miten poistettavien puiden valinta vaikuttaa eri ekosysteemipalveluiden väliseen vaihdantasuhteeseen (kuva 15). Tutkimuksessa käytettäviä mittareita olivat välittömät puunmyyntitulot, jäljelle jäävien puiden arvokasvu, metsän tuottoarvo, jäljelle jäävien puiden koko- ja puulajivaihtelu, tilajärjestys, suojeluarvo sekä maiseman viihtyisyyttä kuvaava indeksi. Koska jokainen puunvalinta vaikuttaa lähes kaikkiin edellä mainittuihin mittareihin epälineaarisesti, poistettavien puiden optimoinnissa tarvitaan heuristista lähestymistapaa. Hankkeessa kehitettiin laskentamenetelmä, jonka avulla puunvalinta voidaan optimoida joko yksittäisten tavoitteiden mukaan tai useampaa tavoitetta painottaen, mikäli leimikosta on saatavissa puukartta.

Poistettavien puiden valinta vaikuttaa metsän rakenteeseen ja ekosysteemipalveluihin pitkäaikaisesti. Luomuhakkuu-hakkuu hankkeessa toistaiseksi on kartoitettu kirjallisuutta metsän rakenteen sekä metsänhoidon ekologisen, sosiaalisen ja taloudellisen kestävyuden kuvaamiseen soveltuvista indikaattoreista, sekä kehitetty ja testattu puunvalinnan optimointia isoilla puukarttakoealoilla (pinta-ala keskimäärin 0,13 ha). Seuraavat kehitystarpeet liittyvät leimikkotason päätösten tukemiseen, kuten leimikkotason vaihtelun automaattiseen tunnistamiseen, leimikon mikrokuvioitiin ja käsittelysuositusten määrittämiseen mikrokuvioille, säästöpuuryhmien optimointiin sekä ajourareitistön huomiointiin poistettavien puiden valinnassa. Keskeinen jatkokysymys on myös se, millainen ja miten esitetty tieto auttaa parhaiten metsäkoneen kuljettajaa työssään. Tieteellinen artikkeli puutasolla tehtävien valintojen optimoinnista sekä eri hyötyjen välisten vaihdantasuhteiden tarkastelusta on parhaillaan vertaisarvioinnissa. IUFRO2024-konferenssissa (Tukholma 25.6.2024) pidetty esitys aiheesta löytyy täältä: http://luomuhakkuu.fi/wp-content/uploads/sites/4/2024/09/IUFRO2024_OptimalTreeSelection_MikkoNiemi.pdf



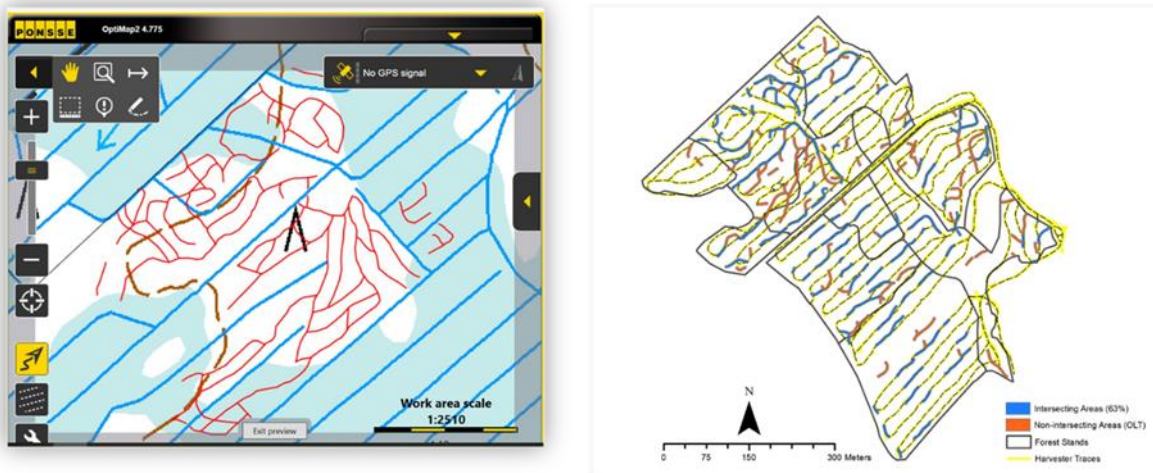
Kuva15: Esimerkkikuva poistettavien puiden valinnasta, kun optimoinnissa on painotettu jäljelle jäävän puuston arvokasvua (60 %) ja puulajisekoitusta (40 %), sekä rajoitettu pohjapinta-ala metsänhoidon suositusten mukaan ja tilajärjestyksen säännöllisyys Clark-Evans-indeksin avulla. DBH = rinnankorkeusläpimitta. Puulajikoodit: 1 = mänty, 2 = kuusi, 3 = rauduskoivu, 4 = hieskoivu, 7 = tervaleppä.

3.1.7 Syväoppimiseen pohjautuva malli vanhojen ajourien mallintamiseksi ja visualisoimiseksi karttatasoksi

Mallin ensimmäinen versio on rakennettu ennen tämän projektin alkamista. Luomuhakkuu-hankkeessa menetelmästä on rakennettu uusi parannettu versio ja menetelmää on testattu käytännön työmailla. Opetusaineistoa varten on kerätty 40 kpl 1x1 km suuruisia kohdealueita Parkanon ja Ikaalisen alueelta. Kohdealueista on digitoitu jokainen havaittu ajoura. Ajouran määrittämiseen on käytetty tiheäpulsisesta laserkeilausdatasta, ilmakuvista johdettuja tunnuksia sekä maastotiedustelua. Opetusaineisto käsittää yhteensä 366 km ajouraa. Laskenta perustuu U-NET -konvoluutioverkkomenetelmään.

Menetelmää on vuonna 2023 testattu käytännön työmaalla Karviassa yhteistyössä Ponsse, Metsä Groupin sekä JP Forest Oy:n kanssa. Kohde oli mäntyvaltainen turvemaakohde, joka oli harvennettu ensimmäisen kerran noin 25-30 vuotta aiemmin. Vanhojen ajourien karttataso, nk. OLT-layer (Old logging trails), tuotiin Opti Map2-ohjelmaan Google kml-formaatissa (Kuva 16 a ja b).

Testi onnistui hyvin. Testin aikana kuljettajat pystyivät hyödyntämään uutta visualisointia uraverkoston suunnittelussa. Hakkuukoneen liikkuminen taltioitiin GNSS-laitteistolla, jonka avulla pääsimme seuraamaan missä määrin kuljettajat seurasivat vanhaa ajouraa. OLT-karttatasot rakennettiin myös simulaattoriympäristöön vietyihin Digital Twin – metsiköihin. Myös simulaattoriympäristössä vanhojen ajourien visualisointi todettiin erittäin hyödylliseksi.



Kuva 16 a ja b. Vanhojen ajourien visualisointi tuotuna OptiMap 2-ohjelmaan (a) sekä vertailu siitä missä määrin kuljettaja seurasi vanhoja ajouria (b).

3.1.8 Algoritmikokonaisuus ajouran keskiviivan sekä metsäkoneiden ajokertojen määrittämiseksi


Olemme kehittäneet algoritmikokonaisuuden, jonka avulla voimme jatkossa paremmin analysoida ajaouraverkoston tarkkaa sijaintia sekä hakkuukoneen ja kuormatraktorin liikennettä eri verkoston osissa. Tähän asti tietojärjestelmiin on tallentunut hankalasti käytettävää, GNSS-paikantamiseen pohjautuvaa reititinjäljitystietoa, jonka paikannustarkkuus vaihtelee metsässä viisikin metriä.

Ajouran keskiviiva lasketaan kaksivaiheisesti. Ensin ajouran jokaiseen kohtaan määritetään keskipiste tiheysfunktion avulla: keskipiste hakeutuu lähelle sitä geometristä pistettä, missä on eniten ajokertoja. Tämän jälkeen tiheysfunktiolla lasketut keskipisteet suoritetaan yhtenäiseksi keskiviivaksi (kuva 17).

Keskilinjan määrittämisen lisäksi uudella menetelmällä voidaan selvittää ajokerrat kullakin ajouran segmentillä (kuva 18).



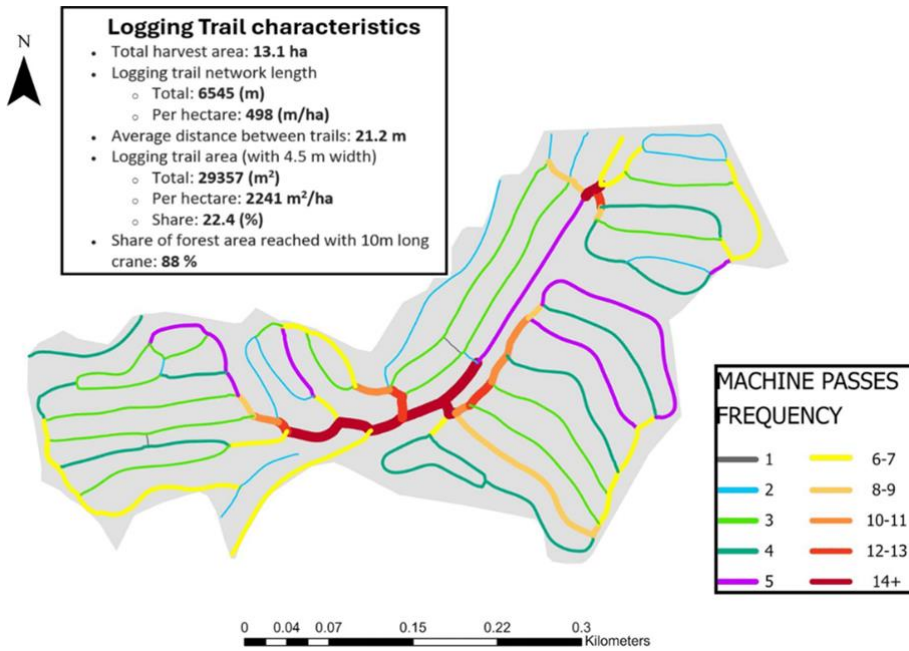
Kuva 17. Hakkuukoneen ja kuormatraktorin reitinjäljitys kullakin ajokerralla on visualisoitu ruskealla viivalla. Punainen viiva kuvaa uudella menetelmällä laskettua ajouran keskilinjaa.



Kuva 18 a ja b. Kuvapari alkuperäisestä hakkuukoneen ja kuormatraktorin liikettä seuraavasta tracking-tiedostosta (a) sekä näistä työstetystä yhdistelmä-tiedostosta (b).

Ajouran keskilinjan määrittämisen avulla voidaan tarkastella ajouraverkoston ja metsäkoneen reitinvalinnan tehokkuutta suhteessa leimikon ominaisuuksiin. Menetelmä kerää tietoa muun muassa koko ajouraverkoston ja sen hehtaarikohtaisesta pituudesta sekä ajourien keskimääräisestä etäisyydestä toisiinsa. Myös esimerkiksi ajourien alle jäävä pinta-ala ja sen osuus koko leimikosta voidaan laskea (kuva 19).

Menetelmä on alun perin kehitetty ArcGISPro-ympäristössä ja eri proseduurit ovat linkitetty yhtenäiseksi kokonaisuudeksi ModelBuilder-työkalun avulla. Olemme rakentaneet kokonaisuudesta myös Python-pohjaisen ohjelmistoversion, joka pystyy tekemään saman tehtäväkokonaisuuden ilman ArcGISPro-ohjelmistoa. Tämä kokonaisuus on tarkoitus julkaista tieteellisenä artikkelina. Ohjelma on jatkossa vapaasti saatavilla.



Kuva 19. Algoritmikonaisuus muodostaa yhteenvedon, jossa ajokertojen määrä eri ajourilla kuvataan väreillä. Laatikossa on kuvan ajouraverkoston tehokkuusluvut.

3.1.9 Metsikön puusto- ja maastotiedon jatkojalostus metsikön digitaalisen kaksoseksi simulaattorikoulutusta varten (alihankinta Creanex Oy)

Hankkeessa on rakennettu digitaalinen kaksonen kuudesta metsikkökuvista; vuonna 2023 kolmesta metsikkökuvista Parkanon alueelta ja vuonna 2024 kolme kuviota Ähtärin ja Padasjoen alueilta. Metsiköiden puutulkinta pohjautuu dronella kuvattuihin tiheäpulsssiin laserkeilausaineistoihin, korkean resoluution RGB- ja väärävärikuviin sekä hankkeessa kehitettyihin syväoppimismalleihin, jotka erottavat puujoukosta yksittäisen puun ääriiviivat sekä tunnistavat ko. kohteen puulajin. Näiden tietojen pohjalta määritetään jokaiselle löydetylle puulle sijainti, puulaji sekä puun pituus.

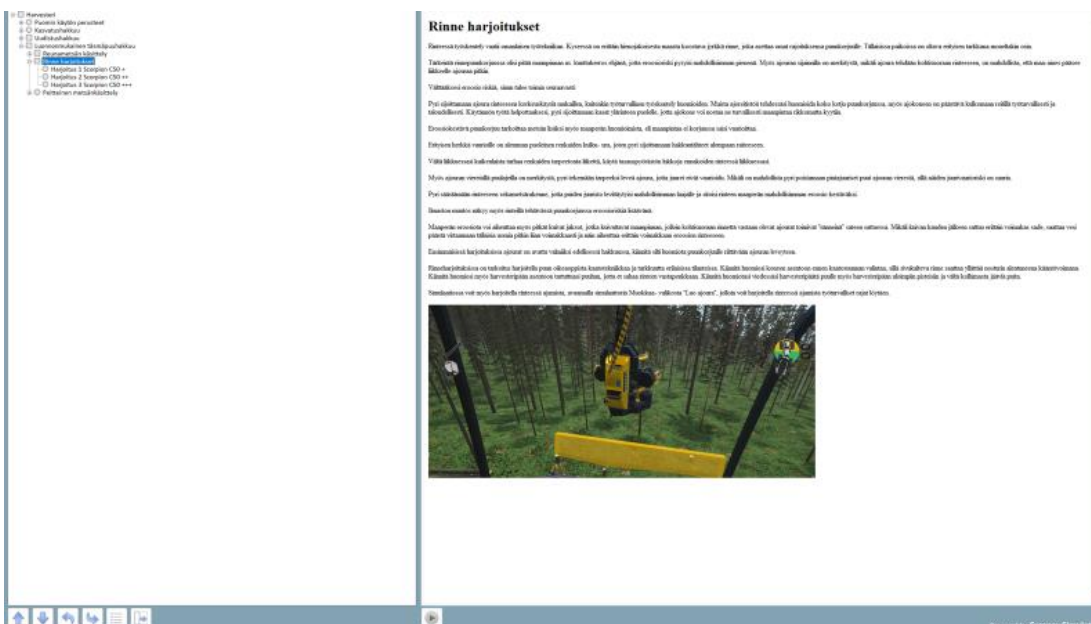
3.1.10 Metsän digitaaliseen kaksoseen pohjautuva metsäkoneen simulaattorikoulutuksen oppimisympäristö

Hankkeessa on kehitetty metsän digitaaliseen kaksoseen pohjautuva metsäkoneen simulaattorikoulutuksen oppimisympäristö. Uusi oppimisympäristö mahdollistaa ilmastokestävän metsätalouden harjoittelun jo koulussa ollessa. Oppimisympäristön avulla varmistamme, että metsäoppilaitoksista valmistuvat metsäkoneenkuljettajat osaavat toimia työssään myös ilmastonmuutoksen mukanaan tuomat sään ääri- ilmiö vaihtelut huomioiden. Kehittämämme tehtävät erityisesti reunametsien käsittelyyn auttavat metsiköitä kohtaamaan erilaiset myrskyt, kuivuuden sekä paahteisuuden aiempaa paremmin (kuva 20). Digitaalisen kaksosen avulla voimme tuottaa kuljettajalle lisätietoa esimerkiksi iltapäiväauringon paahteeseen joutuvista puuyksilöistä tai muuta metsää pidemmistä hakkuussa poistettavista susipuista. Voimme opettaa myös maaperän valmistelua ilmastonmuutoksen tuomiin sään ääri- ilmiöihin hakkuun keinoin. Esimerkiksi tammikuussa lumettomana olevat kuusikot ovat erityisessä riskissä pakkasten tullessa, sillä maanpinnan jäätyessä jäätyvät myös puiden juuret kuusten ollessa pintajuurisia. Osaamalla käsitellä kohde sekapuustoisuutta lisäävällä hakkuu tavalla ja harventamalla kohdetta puuyksilö tasolla saadaan maaperän kosteutta muutettua ilmastokestävämmäksi.



Kuva 20. Ponsse SimTrainer- oppimisympäristö: Reunametsien käsittely tehtävöosion aloituskuva

Erosio herkkiin rinteisiin keskittyvä tehtävöosio pyrkii varmistamaan myös rinnemetsien kestävä käytön, jota on pakko muuttaa nykyisestä käytänteestä säään ääri- ilmiöiden lisääntyessä (kuva 21). Emme voi ottaa jatkossa riskiä, jossa rinteessä ajouralla olevaa maanpintaa paljastuu hakuussa. Ilmaston muutos näkyy jo nyt alkukesän kuivuutena ja loppukesän rankkasateina, jotka aiheuttavat huomattavan eroosioriskin tällaisissa kohteissa. Tehtävöosiossa keskitytään hoitamaan rinteiden käsittely ilmastokestävällä tavalla, jossa metsikön kiertoaika lisätään hallitusti poistettavien puiden valinnalla sekä ajourat sijoitetaan mahdollisimman optimoidusti. Tehtävöosiossa huomioidaan myös alaosan vesistö Pihnarinluoma siten, ettei sinne joudu kiintoainesta eikä sitä ylitetä.




Kuva 21. Ponsse SimTrainer oppimisympäristö: Rinnehakuuta käsittelevän tehtävöosion aloitussivu.

Peitteisen metsänkäsittelyn tehtäväosio on todella monipuolinen, sillä digitaalisen kaksosen avulla voimme tuoda simulaatioon esimerkiksi puiden tuottamat varjot, mikä auttaa ymmärtämään alikasvoksen valonsietoa (kuva 22). Digitaalisen kaksosen avulla saamme jopa pohjaveden pinnan tason esiin, mikä auttaa haihduttavien puiden paikkojen valinnassa. Käytännössä voimme suunnitella hakkuun tämän avulla metsikön kasvukyky säilyttäen sekä hiilensidonta maksimoiden.



Kuva 22. Ponsse SimTrainer oppimisympäristö: Peitteinen metsänkäsittely tehtäväosion aloituskuva

Oppimisympäristömme tarkoitus on lisätä metsiemme sekapuustoisuutta, parantaa maaperää sekä vähentää ilmastomuutoksen mukanaan tuomien sään ääri- ilmiöiden vaikutusta metsiimme (kuva 23). Oppimisympäristömme sijaitsevat 150- 200 metrin korkeudessa merenpinnasta, joka on ilmastomuutoksen kannalta merkittävää aluetta: syksyn myrskyt muuttuvat märeksi lumeksi näillä alueilla ja ne ovat erityisessä lumituhoriskissä. Kuljettajaa opastava karttataso auttavat metsäkoneenkuljettajia ottamaan aiempaa paremmin huomioon myös ilmansuunnat hakkuissa, joiden merkitystä ei aiemmin ole opetettu.



Kuva 23. Ponsse Opti 5G- mittalaitteessa oleva kuljettajaa opastava karttataso, jossa esillä lehtivihreältä heikentyneet puuyksilöt hälyttävänä punaisella, susipuiden sijainti latvuksen muodolla ruskeana sekä mustalla tekoälyn avulla tuotetut ajourat kohteelle.

3.2. Tulosten vieminen käytäntöön

Hankkeessa on tehty samanaikaisesti sekä tutkimusta, tuotekehitystä että tulosten jalkautusta käytäntöön. Varsinaiset tutkimustulokset on julkaistu tai tullaan julkaisemaan tiedejulkaisuissa. Näistä merkittävimpiä ovat yksinpuin tulkinnan kehittäminen, monitavoitteisen puuvalinnan optimointi mikrokuviotasolla, digitaalisen maaperämallinnuksen kehittäminen sekä algoritmit, joilla hyödynnetään edellisessä puunkorjuuoperaatiossa syntynyttä tietoa hakkuukohteen ajouraverkoston suunnittelussa. Kaikki nämä tutkimustulokset tarjoavat erinomaisen perustan uusille käytäntöön soveltuville täsmäpuukorjuuta tukeville tuoteratkaisuille, joita voivat olla esimerkiksi uudet karttatuotteet, puunkorjuun suunnitteluohjelmat sekä innovaatiot kuljettajan opastamiseksi.

Olemme hankkeessa myös laajasti testanneet erilaisia karttatuoteaihioita yhdessä yhteistyökumppaneidemme kanssa. Tärkein opetus on se, että karttatuotteiden visualisoinnin räätälöinti kuljettajan työtä tukeväksi on jopa tärkeämpi tutkimuksen ja tuotekehityksen kohde jatkossa kuin uuden tyyppisen informaation esittäminen sinänsä.

Merkittävin tuotekehityssaavutus hankkeessa on ollut digitaaliseen kaksoseen pohjautuvan simulaattorikoulutuksen oppimisympäristön kehittäminen. Hankkeen loppuvaiheessa yhteistyökumppanimme Ponsse on pystynyt myös monistamaan oppimisympäristön kaikkiin oppilaitoksiin sopivaksi ja Tredu järjesti laajan opetuskiertueen metsäkonekoulujen henkilökunnalle lähes kaikissa Suomen metsäkonekoulutusta tarjoavissa oppilaitoksissa.

Oppimisympäristön koulutuskierueella (10 oppilaitosta yhteensä 44 opettajaa) saamamme palaute piti kehittämäämme oppimisympäristöä erittäin tarpeellisena ja se otettiin vastaan innostuneesti. Erityisen hyvänä tässä oppimateriaalissa pidettiin alan ns. hiljaisen tiedon esiintuomista. Vanhan ajan metsurit osasivat harventaa kuvioiden reunat myrskyjen kestäväksi, mutta tämä taito on uhannut kadota alan koneellistumisen vuoksi, sillä kaatopäätös tehdään nykyisin hakkuukoneen hytistä eikä kannontasolta. Lisäksi poistettavan puun valintaa käytettävä aika on pienentynyt merkittävästi moottorisahahakkuuseen verrattuna. Myös kaikenlaisen kuljettajaa helpottavan teknologian mukaan tuomista kiiteltiin, jota digitaalisen kaksosen avulla voidaan tuottaa.

Metsäalan perustutkimuksen opinnoista on puuttunut metsäekologian opetus 20 vuotta, nyt uudessa opetussuunnitelmassa se on vihdoinkin otettu mukaan osaksi kuljettajakoulutusta, johon kehittämämme oppimateriaali sopii käytännöllisenä erinomaisesti. Tässä hankkeessa kehitetty uusi digitaaliseen kaksosteknologiaan perustuva opetuskokonaisuus otettiin monessa koulussa osaksi opetussuunnitelmaa. Koulutuskierueellamme oli mukana myös muutamia Jotpa- koulutuksia järjestäviä oppilaitoksia, jotka olivat kaivanneet koulutuksiinsa hieman lisää materiaalia.

Erityisen kiinnostavana pidettiin hankkeessa tuotettuja kuljettajaa opastavia karttatasoja ja tähän kehitettyä oppimisympäristöä. Ei ole aivan itsestään selvyyttä, että kuljettaja, joka katsoo metsää, osaisi katsoa samaan aikaan vielä näyttöä ja kiinnittää huomionsa tässä oikeaan asiaan. Mietimme käytännössä, mitkä asiat on hyvä tuoda kuljettajalle tiedoksi, ja mitkä ovat esimerkiksi hälyttävän tason takana. Hankkeessa käyttämämme erilaiset API- rajapinnat olivat aivan uusi asia kaikkien metsäoppilaitosten opettajille, joten merkittäväksi hyödyksi voidaan lukea heidän tietoisuutensa lisääminen koulutuskierueen aikana.

Metsän digitaaliseen kaksoseen pohjautuvan simulaattorikoulutuksen oppimisympäristön kehittäminen on erittäin kiinnostava aihe myös kansainvälisesti. Tredu ja Ponsse osallistuivat syksyllä 2024 AWE EU 2024 - konferenssiin, jossa he esittelivät Luomuhakkuu -hankkeessa kehitettyä opetusympäristöä (kuva 24). Esitys herätti valtavasti kiinnostusta. Opetusympäristö on käännetty myös ruotsin ja englannin kielelle, joten se todennäköisesti leviää nopeasti metsäkoneopetuksen uudeksi standardiksi myös kansainvälisesti.



Kuva 24. AWE EU 2024 tapahtumassa esitelty Digitaalisen kaksosen tarina oppimisympäristöksi

Hankkeen tuloksia on pyritty viestimään tehokkaasti tiedeyhteisössä, ammattilaisten keskuudessa sekä suurelle yleisölle. Tiedeyhteisöä palvelevat tehokkaimmin tieteelliset julkaisut sekä esitykset tieteellisissä konferensseissa. Ammattilaisten keskuuteen hankkeen tulokset siirtyvät tehokkaimmin ohjausryhmätyöskentelyn kautta. Luomuhakkuu-hankeessa on ollut poikkeuksellisen monipuolinen ja laaja ohjausryhmä, jossa on ollut edustus kaikista merkittävimmistä sidosryhmistä (metsäteollisuus, metsäkonevalmistus, metsänomistajat, metsäntutkimus, metsäopetus, hallinto ja viranomaistoiminta sekä metsäsektoria palvelevat ICT-yritykset).

Hankkeen viestintää on koordinoanut Metsäviestintä Oy. Olemme rakentaneet hankkeelle oman internet-sivuston (<https://luomuhakkuu.fi>). Hankkeen tuloksista on kirjoitettu heti niiden valmistuttua lyhyehkö tiivistelmä, jossa esitetään tutkimuksen päätulos helposti ymmärrettävässä muodossa. Tulosten ymmärrettävyyttä on pyritty lisäämään aiheeseen sopivan kuvituksen avulla. Tulostusjulkistamisen näkyvyyttä olemme pyrkinneet lisäämään some-päivitysten avulla. Varsinaisten tulosjulkistamisen lisäksi olemme kirjoittaneet hankkeen kuluessa 3 lehdistötiedotetta. Aktiivisen tiedottamisen kautta Luomuhakkuu-hanke onkin jo tähän mennessä synnyttänyt ainakin kaksi uutta samaa aihepiiriä jatkavaa projektia.

3.3. Tulosten merkitys ja jatkotoimenpiteet

Hankkeen aikana on saavutettu merkittävä digiloikka kohti täsmäpuukorjuuta. Saavuttamamme tulokset ovat arvokkaita sekä tieteellisesti että käytännön kannalta. Merkittävän rahoituksen turvin olemme pystyneet luomaan laajan osaamis pohjan ja ymmärryksen tulevaisuuden täsmäpuukorjuusta. Kaukokartoitustiedon turvin pystymme tulevaisuudessa kehittämään entistä älykkäämpiä tietotuotteita. Tähän tarjoaa parhaimman mahdollisuuden eri datalähteiden yhdistäminen sekä tiedon analysointi spatiaalisen tekoälyteknologian avulla (GeoAI).

Uusien tietotuotteiden kehittämisessä ei ole kysymys pelkästään informaation lisäämisestä tai tarkentamisesta, vaan vähintään yhtä tärkeää on tietotuotteiden räätälöinti metsäsuunnittelijan ja metsäkoneenkuljettajan työtä tukeväksi. Leimikon suunnitteluvaiheessa (maastossa ja toimistossa) ja toteutusvaiheessa (konetyö) tarvittava informaatio on osattava esittää erilaisessa formaatissa. Hierarkkisesti tietyt päätökset tehdään vaihtoehtoisesti alue-, kuvio-, mikrokuvio- tai työpistetasolla. Koneenkuljettajan opastuksessa on ymmärrettävä, että hän pääsääntöisesti katsoo koneesta hakattavaa metsää ja vain satunnaisesti koneen monitoria, joka avustaa päätöksenteossa. Informaatio on siis tarjottava kognitiivisesti ergonomisessa muodossa. Täsmäpuukorjuun tutkimuksen rahoitusta kannattaa ehdottomasti lisätä, sillä sen

kautta meillä on mahdollisuus toteuttaa luontoa kunnioittavaa mutta samalla tehokasta luonnonläheistä metsänhoitoa. Erityisesti biodiversiteetin huomioimiseen uusi teknologia tarjoaa erinomaisen pohjan.

Metsäkoneen aiheuttamien maasto- ja vesistövaikutusten ehkäisyä varten on kehitetty viime vuosien aikana runsaasti erilaisia sovelluksia. Valitettavasti maan kantavuutta on mahdotonta ennustaa tarkasti, mikäli maalajia ei tunneta. Maalaji säätelee, kuinka nopeasti sade vesi valuu pinnasta kohti pohjaa, kuinka suuri osa sadevedestä valuu pintavaluntana eteenpäin, voiko vesi nousta kapillaarisesti pohjavedestä kohti maanpintaa, kuinka paksu orgaaninen kerros kertyy kivennäismaan päälle ja kuinka iso osa maavedestä on kasvien käytettävissä. Tiivistetysti, maalajilla on aivan keskeinen vaikutus metsän kasvuun, kasvillisuuteen, taimettumiseen, metsänhoitomenetelmän ja korjuuajankohdan valintaan. Oikean maalajin tunnistaminen mahdollistaa luonnonläheisemmän metsänhoidon toteutuksen ja hiilensidonnan maksimoimisen.

Suomeen voidaan tulisi pikaisesti rakentaa modernit maalajikartat metsätalouden tueksi. Toteutuessaan tarkat maalajikartat edistävät metsäoperaatioiden ympäristöystävällisyyttä ja metsän monimuotoisuuden ja luonnonläheisemmän metsänhoidon toteuttamista. Maalajikartoilla on myös monenlaisia kerrannaisvaikutuksia metsäntutkimukseen (kasvufysiologia ja -ekologia, kasvihuonekaasulaskenta) sekä metsänhoidon opetukseen kaikilla koulutusasteilla.

4 Hankkeen päätulokset ja toimenpidesuositukset

Hankkeen aikana on saavutettu merkittävä digiloikka kohti täsmäpuukorjuuta. Tämä tarkoittaa, että metsän kasvatuksen, ympäristönäkökuulmien ja metsäoperaatioiden toteutuksen kannalta olennaiset metsän piirteet ja rakenteet ennustetaan kaukokartoituksen pohjautuvien mallien avulla ja tämä tieto tuodaan puunkorjuun toteuttajien avuksi operaatioita toteutettaessa.

Hankkeen merkittävimmät tulokset ja niihin liittyvät toimenpidesuositukset ovat seuraavat

- **Päätulos 1:** Metsikön puut voidaan tehokkaimmin tunnistaa kaukokartoitusdatan avulla yhdistelemällä eri datalähteitä (laser, ilmakuva ja vääräväri) ja hyödyntämällä syvöppimisistä
 - o Toimenpidesuositus 1: Metsiköstä laadittu puukartta mahdollistaa metsikön eri mikrokuvioiden tarkastelun ja puuvalinnan räätälöimisen metsänomistajan tavoitteita mukailien
 - o Toimenpidesuositus 2: Puukarttatuotteet tulee huolellisesti räätälöidä metsäkoneen kuljettajille sopivaksi. Koneenkuljettajan työtä helpottaa erityisesti erikoispuiden (lahot puut, erityisen kookkaat puut, lehtipuut) paikallistaminen etukäteen ja visualisoiminen karttatasolle
 - o Toimenpidesuositus 3: Metsäkoneenkäyttäjän tueksi on tulevaisuudessa myös rakennettava karttataso, joiden avulla havainnollistetaan metsänhoidon kannalta tärkeitä yksityiskohtia puunkorjuukuviolla (paahteisuudelle alttiit reunametsät, eroosioherkät rinteet, tuulituhoille alttiit kohteet, jne).
- **Päätulos 2:** Metsikön maalajit voidaan nykyistä paremmin tunnistaa mikrokuviotasolla käyttämällä modernin digitaalisen maamallinnuksen tekniikoita (digital soil mapping). Hienojakoisia maalajeja selittävät parhaiten topografiatunnukset, satelliittidatasta johdetut kasvillisuusindeksit.
 - o Toimenpidesuositus 4: Suomesta on kerättävä riittävän kattava paikkatietopohjainen maalajinäyttekokonaisuus, joka mahdollistaa uusien maalajikarttojen rakentamisen Suomeen
- **Päätulos 3:** Edellisessä puunkorjuuoperaatiossa syntynyttä tietoa ajouraverkostosta (kaukokartoituspohjainen tulkinta tai metsäkoneen reitinjäljitystieto) voidaan tulevaisuudessa käyttää monipuolisesti hyödyksi hakkuukohteen ajouraverkoston suunnittelussa

- Toimenpidesuositus 5: Tulevaisuuden tehokas ajouraverkoston optimointiin tarkoitettu algoritmikokonaisuus yhdistää tietoa edellisistä operaatioista sekä käyttää apuna puukarttaa, topografia- ja kosteuskarttoja sekä maalajitietoa.
- Päättulos 4: Metsän digitaaliseen kaksoseen pohjautuva metsäkoneen simulaattorikoulutuksen oppimisympäristö luo mahdollisuuden opettaa ilmastokestävää metsänhoitoa metsäkoneen kuljettajille
 - Toimenpidesuositus 6: Metsäkoneenkäyttäjien perus- ja jatkokoulutukseen tulee sisällyttää myös metsänhoitoa; erityisesti reuna-alueiden ennakoiva käsittelyä, eroosioherkkien kohteiden tunnistamista ja peitteisen metsänkäsittelyn toteutusta.
 - Toimenpidesuositus 7: Metsäkoneeseen kehitettävien karttatasojen hyödyllisyyden tutkimukseen tulee jatkossa kiinnittää enemmän huomiota (käyttäjänäkökulma). Karttatasojen standardisointi mahdollistaa tiedon paremman hyödyntämisen kaikissa puunkorjuukohteissa.