Luke, Metsäteho,
Arbonaut, HY,
ISY, GTK

3.6.2019

LOPPURAPORTTI

MMM:n Metsätieto ja sähköiset palvelut -hanke, Teema: Olosuhdetieto mukaan metsätietoon

Metsäoperaatioiden tehostaminen ja laadun parantaminen olosuhdetiedon hyödyntämisen avulla -MEOLO

Enhancing efficiency and quality of forest operations by information on working conditions

1. Tutkimuksen tavoitteet

MEOLO -hankkeen päätavoitteena oli kehittää menetelmiä, joilla puunkorjuun ja metsänhoitotöiden kannalta oleelliset olosuhdetiedot saadaan kustannustehokkaasti tuotettua paikkatietopohjaisiin suunnittelu- ja ennustusjärjestelmiin. Keskeisimpiä olosuhdetietoja ovat säähavaintojen lisäksi maalaji ja maan fysikaaliset ominaisuudet, kivisyys, maaperän boniteetti sekä topografia ja siitä johdettavat mm. maankosteuden paikallista vaihtelua ennustavat muuttujat. Hankkeen tavoite jakaantui seuraaviin osatavoitteisiin:

1. Varustaa metsäkone anturitekniikalla, joka mahdollista maaperän kantavuus- ja muun olosuhdetiedon keräämiseen sekä kehittää menetelmiä kerätyn tiedon hyödyntämiseksi puunkorjuu- ja metsänhoitotöiden suunnittelussa ja toteutuksessa.

2. Testata paikkatietoaineistoihin perustuvien hilatasoisten kulkukelpoisuusmallien kulkukelpoisuusluokitusta käytännön toimintaympäristössä

3. Kehittää ja testata mallinnusmenetelmiä, joilla säätilan aiheuttamat dynaamiset muutokset (routa, maankosteus, lumi) maaperän kantavuudessa ja kulkukelpoisuudessa voidaan ennustaa hilatasolla.

4. Tarkentaa tietoaineistoja korjuukelpoisuuden ja metsänhoidon suunnittelun tarvitsemasta maaperätiedosta.

5. Testata potentiaalisia kaukokartoitusmenetelmiä nykyistä tarkempien hilatason olosuhdetietojen tuottamiseksi. Tarkempien olosuhdetietojen avulla voidaan parantaa sekä puuntuottamisen että puunhankinnan kustannustehokkuutta.

6. Kehittää ja pilotoida kustannustehokkaita ja mahdollisimman automaattisia omavalvonnan menetelmiä maasto-olosuhdetietojen tuottamiseksi

2. Tutkimusosapuolet ja yhteistyö

Hankeen toteutukseen osallistuvat seuraavat tahot:

Luonnonvarakeskus (Luke), jonka vastuulla oli hankkeen koordinointi, yhteistyön sovittaminen muiden käynnissä olevien hankkeiden kanssa, manuaalisen aineiston keruun toteutus, Työpaketin 1 (TP1) tulosten laskenta ja raportointi, ja osallistuminen TP3 toteutukseen. Hankkeen johtajana toimi Jori Uusitalo. Hankkeeseen osallistuvat lisäksi: Leena Finér, Jari Ala-Ilomäki, Matti Siren, Harri Lindeman, Aura Salmivaara, Samuli Launiainen, Juha Heiskanen, Hannu Ilvesniemi ja Ville Hallikainen

Metsäteho Oy:n vastuulla oli töiden omavalvontaan liittyvä työpaketin (TP5) toteuttaminen, osallistuminen urasyvyyden mittauskokeiluihin (TP1) sekä Arbonautin kehittämän korjuukelpoisuusluokituksen käyttöönoton tukemiseen sekä toimijoille tehdyn palautekyselyn toteutukseen (TP2). Metsätehosta hankkeeseen osallistuvat Jarmo Hämäläinen, Asko Poikela, Markus Strandström ja Heikki Ovaskainen.

Arbonaut Oy kehitti ja tuotti staattisen kulkukelpoisuusluokituksen valituille pilottialueille (TP2) ja osallistui TP3:ssa tehtävien korjuukelpoisuusennusteiden kehittämiseen sää- ja maaperätiedon avulla analysoimalla kaukokartoitus- ja paikkatietoaineistoja tutkimus- ja kehitystoiminnan tarpeisiin. Arbonautista hankkeeseen osallistuvat Jussi Peuhkurinen, Anne Seppänen, Risto Rautiainen, Maria Villikka, Ville-Matti Vartio, Tuomo Puumalainen, Ilya Bobylev ja Tomi Karjalainen.

Itä-Suomen yliopiston (ISY) vastuulla oli TP3:n osatehtävä 3 sekä TP:4 osatehtävä 1. Itä-Suomen yliopiston osuuden projektipäällikkönä toimii Timo Tokola. Muina tutkijoina hankkeeseen osallistuivat Ulla Matila, Mikko Härkönen, Matias Vänttinen ja Esa Kärkkäinen.

Helsingin yliopiston (HY) vastuulla on TP2:ssa osallistua Arbonautin korjuukelpoisuusmallien testaukseen (osatehtävä 1) sekä olla mukana staattista korjuukelpoisuusluokituksen kehittämisessä (osatehtävä 2). Lisäksi Helsingin yliopisto osallistuu TP:n 1 menetelmäkokonaisuuden testaamiseen. Hankkeeseen osallistuvat Mikko Vastaranta, Markus Holopainen, Ville Luoma ja Ville Kankare.

Geologian tutkimuskeskus (GTK) vastasi maan vesipitoisuuden (*in situ* ja kaukokartoitus) mittaamisesta ja kantavuuden estimoinnista (TP 4 osatehtävä 2). GTK avusti muita tutkimuslaitoksia analyysien tekemisessä sekä toimitti tarvittavia aineistoja testikäyttöön. GTK:sta hankkeeseen osallistuivat Raimo Sutinen, Pekka Hänninen, Mira Markovaara-Koivisto, Jukka-Pekka Palmu, Ilkka Aro ja Juha Majaniemi.

Varsinaisten partnereiden lisäksi on projektissa tehtiin yhteistyöstä seuraavien organisaatioiden kanssa:

Creanex Oy (yhdyshenkilö Antti Peltola) ja **Argone Oy** (Mikko Miettinen) osallistuvat yhteistyökumppaneina ja alihankkijoina anturi- ja analyysijärjestelmän toteuttamiseen. **Ponsse Oyj** (Kalle Einola) tuki hanketta antamalla riittävän taustatuen järjestelmien yhteensovittamisen mahdollistamiseksi.

Tampereen teknillinen yliopisto (nykyisin Tampereen yliopisto) osallistui anturi- ja analyysijärjestelmien kehittämistyöhön työpaketeissa 1 ja 5. Tutkimustyöstä vastasivat Risto Ritala ja Lari Melander.

3. Tutkimustulokset

3.1. Raiteen mittaus ja kulkukelpoisuuden arviointi metsäkoneen työskentelyn yhteydessä (TP1)

Luke kehitti yhdessä yhteistyökumppaninsa Argonen kanssa sovelluksen, joka mittaisi laserkeilauksen avulla raiteen syvyyttä metsäkoneen työskentelyn aikana automaattisesti. Sovellus koostuu kannettavasta tietokoneesta, ohjelmistosovelluksesta, laserkeilaimesta sekä erillisestä GPS-laitteesta. Sovellus toimii itsenäisesti ja sitä ei tarvitse kytkeä metsäkoneen omaan ajotietokoneeseen.

Laserkeilaimen toimivuutta ajouran syvyyden automaattisessa mittauksessa testattiin kahdessa erillisessä kokeessa, vuonna 2016 Vihdin alueella ja vuonna 2017 Kurussa. Vihdin kokeessa laserkeilain asennettiin noin 45 asteen kulmaan. Kokeessa havaittiin, että laserkeilauksen automaattisen havainnoin avulla ajourapainuman keskivirhe käsimittaukseen verrattuna on 3,5 cm. Laserkeilausmenetelmä saatiin työstettyä niin tehokkaaksi, että merkittävää harhaa ei löytynyt (Salmivaara et al. 2018). Kurun kokeessa laserkeilaimen asento muutettiin siten, että se oli lähes kohtisuoraan maata kohden. Kurun kokeessa mittauksen keskivirhe oli ainoastaan noin 1,5 cm. Kurun kokeessa oli toki keskimäärin huomattavasti pienemmät raiteet kuin Vihdissä.

Testien tuloksena voidaan sanoa, että raiteen mittaus laserkeilaimen avulla on periaatteessa täysin mahdollista. Menetelmän heikkoutena voidaan pitää sitä, että keilan joudutaan asentamaan kuormatilaan kiinni, joten se on erityisen vaurioitumisherkkä. Luotettava mittaus vaatisi todennäköisesti kaksi erillistä keilainta. Koska keilaimet ovat edelleen kohtuulliset kalliita, muodostuisi vastaavan applikaation investointi- ja käyttökustannukset varsin kalliiksi. Laserkeilaimia tuskin tullaan lähiaikoina asentamaan kuormatraktoreihin muutoin kuin tutkimuskäyttöön.

Luke on myös kehittänyt menetelmän, jolla hakkuukoneen CAN-väylästä taltioidun informaation avulla voidaan estimoida maaperän ominaisuuksia. Menetelmää on hankkeen aikana kehitetty ja testattu vuonna 2016 Vihdissä, vuonna 2017 Kurussa ja vuonna 2018 Siuntiossa. Menetelmä perustuu seuraavaan päättelyketjuun:

- Vakionopeudella tasamaalla moottoriteho käytetään voimansiirron välityksellä kulkuvastuksen voittamiseen
- Kulkuvastus riippuu lähinnä pyörien uppoamasta
- Pyörien uppoama riippuu maan lujuudesta suhteessa siihen kohdistettuun kuormitukseen

Menetelmä vaikuttaa hyvin lupaavalta. Järjestetyissä kokeissa on pystytty osoittamaan, että menetelmä toimii myös teloilla varustetulla hakkuukoneella (Ala-Ilomäki ym. 2019). Hakkuukoneen moottoriteho voidaan yhdistää paikkatietoon ja maaperän kulkuvastuskerroin voidaan tallentaa maastosta hakkuukoneen kulkeman reitin osalta (kuva 1).

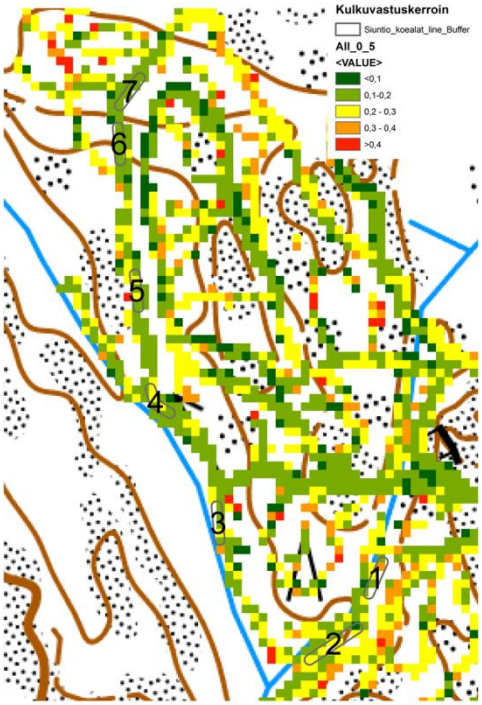

Kuva 1. *Kulkuvastuskertoimet Siuntion koealueella.*

Tampereen yliopisto (TAU) kehitti lasermittausten rinnalla time-of-flight –tekniikalla toteutettua urasyvyyden mittausta. Laitteena käytettiin Kinect 2 –syvyyskameraa, joka oli erikseen suojattu ja kiinnitetty ajokoneen takapankkoon. Urasyvyyksien mittaaminen onnistui noin 3-4 senttimetrin keskimääräisellä virheellä manuaalimittauksiin nähden. Time-of-flight -mittaustavan etuna lasermittauksiin on datapisteiden korkea määrä, jolloin myös koneen nopeutta ja paikkaa voidaan seurata helposti. Huonoja puolia tutkitulla laitteella olivat mittausten kantama ja kirkkaan auringonpaiston sietäminen. Vastaavaa laitetta ei ole tällä hetkellä saatavilla metsäkelpoisena. Projektin tulokset on esitelty julkaisuissa (Melander & Ritala 2018) ja Metsätehon raportissa (Ovaskainen 2019).

3.2. Leimikoiden korjuukelpoisuusluokittelu (TP2)

Työpaketissa jatkettiin Arbonaut Oy:n Forest Big Data -hankkeessa (FBD-hanke) kehittämän hilatasoisen kantavuusluokitusmenetelmän (korjuukelpoisuusluokitus) kehittämistä ja toteutettiin menetelmän testaus. Lisäksi tutkittiin menetelmän kehittämistä maaperäkartta-aineiston avulla.

Jatkokehitystä varten korjuukelpoisuuskartat tuotettiin FBD-hankkeessa kehitetyillä menetelmillä neljälle suuralueelle. Metsäteho organisoi osakkailtaan yhdessä Arbonaut Oy:n kanssa maastohavainto/-palauteaineiston keruun suuralueilta. Aineistoa kertyi 115 lohkolta (631 ha) 856 pistehavaintoa. Aineistoa käytettiin menetelmän validointiin sekä mallin seuraavan version opetusaineistona. Palautekyselyn perusteella ensimmäisen malliversion

tuottama yhteensopivuus asiantuntijan tekemän lohkotason maastoarvion kanssa oli kivennäismailla noin 90 % ja turvemailla 60–70 %. Palautteen perusteella malli tuottaa suunnittelun tarpeisiin kohtalaisen hyvän arvion korjuukelpoisuudesta. Menetelmän tuottama ennuste oli varovainen, mutta sen todettiin paikkaavan hyvin paikallistuntemuksen puutteita. Vastausten perusteella korjuukelpoisuuskartta olisi parhaimmillaan etsittäessä isommasta turvemaakeskittymästä lupaavimpia kesäkorjuuseen soveltuvia alueita.

Pistemuotoinen palauteaineisto mahdollisti mallin kehittämisen, koska opetusaineistona käytettävien havaintopisteiden lukumäärä nelinkertaistui alkuperäisestä 296:sta 1152:an ja myös niiden maantieteellinen kattavuus parani. Parannettu malli tuotti paremmin havaintoaineiston kanssa yhteensopivan ennusteen ja esimerkiksi vähensi edellisen mallin ”varovaisuutta”. Parannetun mallin muoto oli myös loogisempi ja mallin soveltaminen yksinkertaisempaa.

Mallin päivittämisen ohella määriteltiin korjuukelpoisuuskartan teemoitus ja poikkeustilanteiden käsittely (vesistöt, puuttuva aineisto jne.) Suomen metsäkeskuksen kanssa. Hankkeessa tehdyn kehitys- ja määrittelytyön perusteella korjuukelpoisuusluokittelu voitiin tuotteistaa erillisessä hankkeessa korjuukelpoisuuskartoiksi.

Testaus tehtiin korjuukelpoisuuskartoille, jotka ovat jaossa Suomen metsäkeskuksen kautta. Hankkeen aikana korjuukelpoisuuskarttoihin on tehty joitain käyttäjäkokemusta parantavia muutoksia. Nämä muutokset eivät kuitenkaan vaikuta metsämaalla luokituksen lopputulokseen.

Testaus tehtiin kahdella menetelmällä. Ensimmäisessä menetelmässä luokitustulosta validoitiin korjuuvauriomittausten avulla (Kankare ym. 2019). Toisena menetelmänä oli aineiston käyttäjille suunnattu kyselytutkimus.

Korjuukelpoisuuskartan testauksen ensimmäisessä vaiheessa (Kankare ym. 2019) tavoitteena oli arvioida luokitustulosta maastossa tehtyjen korjuuvauriomittausten avulla. Analyysiin valittiin yhteensä 67 harvennushakkuukuviota kolmelta eri tutkimusalueelta, joista mitattiin yhteensä 225 kappaletta 30 metrin pituista hakkuukoneuraa. Korjuuvauriomittaukset sijoitettiin hakkuukoneurille niin, ettei korjuukelpoisuuskartan luokka vaihdu yksittäisen uran sisällä. Jokaiselta uralta mitattiin kaikkien yli 1 metrin pituisten painumien kokonaispituus, joissa painuma oli yli 10cm kivennäismailla ja yli 20cm turvemailla. Korjuuvauriomittausten sijoittamisessa tavoitteena oli myös, että mittauksia tulisi jokaisesta korjuukelpoisuuskartan luokasta hakkuuajankohdan vastatessa tai ei vastatessa kartan luokkaa. Analyysi tehtiin sekä kuvio- että hakkuukoneuratasolla.

Tulokset osoittivat, että korjuukelpoisuuskartan luokitus on luotettava mutta hieman konservatiivinen, koska valtaosa hakkuukuvioista (93,8%) harvennettiin ilman Metsälakirajoja ylittävää vauriota, jos hakkuuajankohta vastasi korjuukelpoisuuskartan luokkaa. Korjuuvaurioita havaittiin ainoastaan kohteilla, jotka ovat hakattavissa kuivana kesänä tai talvikaudella. Hakkuukoneuratasolla vaurioita havaittiin keskimäärin ainoastaan 12,6% urista, jos hakkuuajankohta vastasi korjuukelpoisuuskartan luokkaa. Uravauriot olivat keskimäärin 27,6cm syviä ja 12,6m pitkiä. Jos hakkuuajankohta ei vastannut korjuukelpoisuuskartan

luokkaa, Metsälakirajan ylittäviä korjuuvaurioita havaittiin kaikissa korjuukelpoisuuskartan luokissa mutta valtaosa hakkuukoneurista säilyi ilman vaurioita.

Metsäteho selvitti joulukuussa 2018 lähetetyllä kyselytutkimuksella korjuukelpoisuuskarttojen käytettävyyttä ja käyttötapoja. Kysely kohdennettiin Metsätehon osakkaiden ja osakkailla sopimussuhteessa olevien korjuuyritysten toimihenkilöille, sekä koneenkuljettajille. Vastauksia saatiin yhteensä 100 kpl.

Palvelun tunnettuus osoittautui hyväksi (93 %) mutta karttojen saatavuus rajoitti vielä kyselyhetkellä niiden käyttöä: vajaa neljännes vastaajista ilmoitti, ettei kartat ole vielä syystä tai toisesta käytettävissä. Noin 40 % karttapalvelujen piirissä olevista ilmoitti käyttävänsä niitä aktiivisesti eli vähintään muutaman kerran kuukaudessa. Yleisin käyttöalusta on puunhankintaorganisaation oma paikkatietosovellus, myös WoodForce on melko laajasti käytössä. Metsäkeskuksen tarjoamat palvelut tunnetaan huonommin. Tyypillisin käyttötapaus on korjuu ennakkosuunnittelu mutta karttoihin turvaudutaan usein myös toteutusvaiheessa.

Vastaajien antama yleisarvosana (1-5) korjuukelpoisuuskartalle palveluna ja työkaluna oli 3,3. Siihen oltiin sitä tyytyväisempiä mitä pidempään kartta oli ollut käytettävissä. Kehittämistarpeita tunnistettiin ja kehitysideoitakin saatiin. Kattavuuden lisäksi karttojen erottelukykyyn toivottiin parannuksia mm. hienojakoisten maiden ja talvikohteiden osalta. Kolmannes vastaajista kaipasi ohjeistusta karttojen käyttöönottoon ja käyttöön.

Korjuukelpoisuusluokituksen kehittämistä tutkittiin hyödyntämällä avoimena aineistona saatavaa GTK:n maaperäkarttaa. Korjuukelpoisuusluokitus huomioi maalajin vain karkealla jaolla kivennäismaa/turvemaa. Tällöin esimerkiksi hienojakoiset kivennäismaat (mm. savi) voivat saada korjuukelpoisuuskartassa liian hyvin kantavan luokituksen ja vastaavasti karkeat kivennäismaat (mm. hiekka ja sora) liian huonon kantavuuden luokituksen. Maaperäkarttaa on saatavilla 1:200 000 mittakaavassa koko maahan ja 1:20 000 mittakaavassa osaan maata, lähinnä Etelä-Suomeen. Kehittämisessä tutkittiin molempia aineistoja. Tutkimusaineistona oli sama 1152 koealan aineisto, jolla oli laadittu edellinen malli. Kaikkia 1152 koealaa voitiin käyttää 1:200 000 maaperäkartan kanssa. Tarkemman maaperäkartan alueella oli vain 256 koealaa. Maaperäkarttaa hyödyntävät mallit oli rakennettu edellisen mallin antaman ennusteen (ts. korjuukelpoisuuskartan) päälle siten, että niitä voitiin soveltaa jälkiprosessointina. Maaperäkarttamallit toimivat loogisesti siten, että alkuperäisen korjuukelpoisuuskartan luokkaa joko parannettiin tai heikennettiin yhdellä luokalla, jos maalaji oli joko karkea tai hienojakoinen. Maaperäkarttaa hyödyntämällä oikeinluokitusprosentti opetusaineistossa parani noin 10 % 1:200 000 aineistolla ja noin 20 % 1:20 000 aineistolla verrattuna alkuperäiseen, vain kivennäismaa/turvemaa jaottelua hyödyntävään malliin.

Kaukokartoitus- ja kartta-aineistoa hyödyntävää lähtökohtaa sovellettiin myös sorateiden kuntoluokituksessa. Menetelmässä analysoidaan tien leveyttä, ojien kuntoa, puuston varjostavuutta, topografiaa ja maalajia. Menetelmän kehittäminen on saatu hyvin alkuun ja menetelmän soveltaminen vaikuttaa lupaavalta. Kehittäminen on kuitenkin hyvin alussa ja varsinaisia tuloksia ei vielä ole.

3.3. Korjuukelpoisuusennusteiden kehittäminen olosuhdetiedon avulla (TP3)

3.3.1 Maaperän hydrologiset tunnukset

Lukessa on kerätty yhteen kattava hydrologisia ominaisuuksia kuvaava maaperä-aineisto, jotka pohjautuvat vuosina 2007 ja 2008 kerättyyn Biosoil- ja VMI-dataan. Tämä kokonaisuus kattaa noin 600 koealaa ja 2000 maanäytettä. Tavoitteena on ollut analysoida, miten maaperän ominaisuudet vaihtelevat ja voidaanko maaperän ominaisuuksia ennustaa topografia- ja puustontiedon avulla.

Pituusboniteetillä on selkää yhteys maan hienojakoisuuteen ja veden pidätyskykyyn. Maaperän savisuuden (massaosuus >10%) todennäköisyyttä voidaan ennustaa maaperän kaltevuuden, männyn osuuden, korkeuden merenpinnasta ja keskimääräisen sademäärän pohjalta. Humuskerroksen paksuutta voidaan ennustaa metsätyypin, kuusen osuuden, kosteusindeksin (TWI) ja lämpösumman avulla. Projektin tulokset ovat esitetty laajemmin kahdessa julkaisussa (Heiskanen ym. 2018, Heiskanen ym. 2019).

3.3.2 Kulkukelpoisuuden ajalliseen vaihteluun vaikuttavien tekijöiden mallinnus (Luke)

Luken tutkijat ovat kehittäneet SpatHy-mallin, joka estimoi säädatan ja topografian pohjalta metsämaan pintaosien kosteuden kullakin ajan hetkellä. SpatHy on yksinkertainen spatiaallinen hydrologia-, ravinne- ja pohjavesi malli, joka koostuu seuraavista elementeistä:

- StandGrid: rasteripohjainen maanpäällinen hydrologiamalli
- BucketGrid: pintajuuristo/pintamaa -malli
- Topmodel: topografia-pohjainen pohjavesi-malli

Mallin kehitystyötä on tehty yhteistyössä EFFORTE- ja FOTETRAF- hankkeiden kanssa. Mallista on rakennettu demonstraatio Vihdin alueelle (https://wetness.luke.fi/wetnessdemo/)

3.3.3 Dynaamiset kulkukelpoisuusennusteet (UEF)

Korjuu tai kulkukelpoisuuden hyvyyteen vaikuttavat useat erilaiset tekijät. Yleensä nämä luokitellaan staattisiin ja dynaamisiin tekijöihin. Staattisia tekijöitä ovat mm. maalaji, ojitustilanne ja rinteen kaltevuus. Dynaamiset tekijät vaihtelevat voimakkaasti esimerkiksi riippuen vuodenajasta: routa, kosteus ja lumen syvyys. Nykypäivänä on paljon saatavilla paikkatietoa, millä on käyttöarvoa korjuukelpoisuuden arvioinnissa. Ongelmana kuitenkin voi olla paikkatiedon vanhentuneisuus ja epätarkkuus, sekä korjuukelpoisuuteen vaikuttavat dynaamiset tekijät, eli voimakkaasti muuttuvat tekijät. Lisäksi metsäkoneiden ominaisuuksilla on vaikutusta kulkukelpoisuuteen.

Osatutkimuksen ensimmäisessä vaiheessa tehtiin empiirinen koe eri muuttujien käytöstä vierintävastuksen ennustamisessa. Kosteusindeksi on yleisesti käytetty menetelmä, jolla maaperän kosteutta arvioidaan. Tulokset kosteusindeksin ja ajourapaunaimien välisestä suhteesta ovat rohkaisevia. on verrannut metsäkuormatraktorin vierintävastuksen, tehon ja ajourapainaumien suhdetta kosteusindeksin ja eri gammasäteilyarvojen välisiä suhteita

(Kärkkäinen 2017, Mattila & Tokola 2019). Pienestä alueesta ja gammasäteilyarvojen hajonnasta huolimatta, tulokset ovat johdonmukaisia ja paljastavat yhtäläisyyksiä näiden välillä.

Osatutkimuksen toisessa vaiheessa luotiin malli, jolla pystyy arvioimaan heikosti kantavien metsämaiden kantavuutta tyypillisellä metsäkuormatraktorilla syksystä lopputalveen saakka. Tarkastelun rinnalle otettiin nykyään Metsäkeskuksen hallinnoima korjuukelpoisuusmalli, jota vertailtiin luodun dynaamisen maalajimallin kanssa. Korjuu- ja kulkukelpoisuutta lähestyttiin kahdesta eri näkökulmasta, sillä yleinen korjuukelpoisuusluokittelu perustuu voimakkaasti kosteusindeksiin, kun kehitetty menetelmä perustuin maalajien välisiin eroihin. Ennusteet perustuivat Silversides & Sundbergin (1988) esittämiin laskentamalleihin, jolla ajoneuvon kantavuutta eri maalajeilla ennustetaan. Onninen (1996) on kehitellyt mallia siten, että roudan paksuus otetaan huomioon maalajien kantokyvyssä. Näiden laskelmien taustalla on plastisuusteoria, jolla arvioidaan maaperän maksimaalista kantokykyä, kun siihen kohdistetaan painetta tietyllä pinta-alalla.

Tyhjällä metsäkuormatraktorilla kantavuus ei hiesusta ja rahkaturpeesta poikkea kovin paljon toisistaan. Tämä selittyy paljon sillä vaadittava pakkasmäärä molemmilla maalajeilla tyhjänä ei poikkea paljoa toisistaan. Hiesu on aivan kantavuuden rajamailla, tarvittavan pakkasmäärä olevan vain 2 ja rahkaturpeella 25. Tällaiset pakkasmäärät ovat helposti saavutettavissa yhden vuorokauden aikana. Saraturve kantaa keskimäärin 10 vuorokautta myöhemmin kuin rahkaturve. Lieju taas 26 vuorokautta myöhemmin kuin saraturve. Hienolla hiedalla ja hiesulla poikkeama kantavuudessa on alhainen täydellä kuormatraktorilla johtuen pienestä erosta vaadittavasta pakkasmäärästä (kuva 2). Kuvasta huomataan, miten erityisesti rahka- ja saraturpeella kantavuuden ajankohdan jakautuminen on tasaista. Saraturve kantaa keskimäärin kolme viikkoa myöhemmin kuin rahkaturve. Lieju kantoi täyttä kuormatraktoria vain viitenä vuotena 20 vuoden aineistossa (25%). Tyhjän kuormatraktorin kantavuus ei poikkea paljoa täyteen kuormatraktoriin verrattuna paremmin kantavilla maalajeilla. Ero kantavuuden alkamisesta korostuu heikommin kantavilla maalajeilla. Keskihajonta on alhaisempi tyhjällä kuormalla, mutta ero korostuu myös tässä vasta heikommin kantavilla maalajeilla. Liejun tuloksia täydellä kuormalla ei voida pitää yhtä pätevinä ottaen huomioon, että se kantoi vain neljäsosassa aineiston vuosissa.

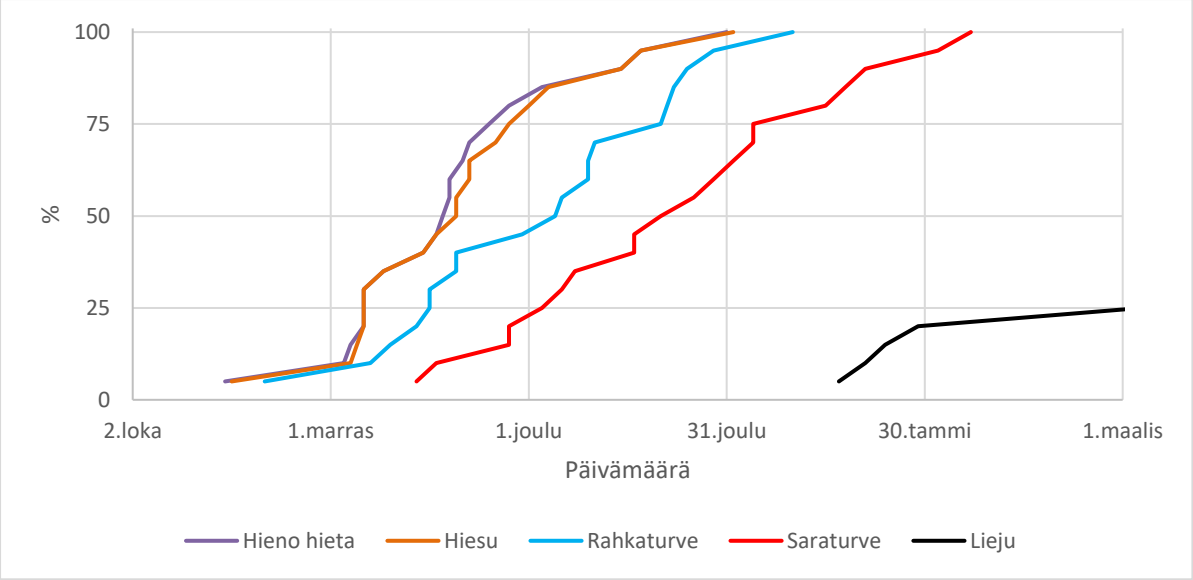

Kuva 2. *Täyden metsäkuormatraktorin todennäköisyys kantavuudelle eri ajankohtina menneiden vuosien perusteella. Liejumaiden kantavuus aikavälillä toteutui vain 25% aineiston vuosista.*

Jotta luotua maalajien kantavuusarvioita voidaan vertailla korjuukelpoisuuskarttaan, miten korjuukelpoisuusluokittelu ja maalajit ovat yhtäläisiä keskenään. Koealueen maalajien ja KKL-kartan spatiaalisuutta tarkastellaan. Korjuukelpoisuuksien vertailu tehtiin koealueella, jonka visuaalinen tulos on esitetty kuvassa 3.

Kantavuuden laskentamallilla on potentiaali laskea tarkasti kantavuutta hyvinkin erilaisille metsäkoneille. Kosketuspinta-alan pystyy myös laskemaan muokkaamalla kaavoja. Se on lopputulokseltaan yksinkertaisesti ymmärrettävä sillä se paljastaa, että metsämaa joko kantaa tai ei. Toisaalta mallia voi muotoilla siten, että se arvioi suurimman mahdollisen kuorman massan tai tarvittavan pakkasmäärän kantavuudelle. Metsätehon maastovaurioriski-arvio tukee kantavuuden arvioimisten tuloksia. Rahka- ja Saraturve ovat tulosten perusteella selkeitä talvileimikoita, ja niiden kantavuus mukailee maastovaurioriskiä kuukausittain.

Maalajien erot korostuvat aineistossa suuresti. Kun tarkastellaan turvemaita (rahkaturve ja saraturve) huomataan selkeä ero kantavuuden ajoittamisessa. Saraturve on huomattavasti heikommin kantava maalaji. Kun rahkaturve kantaa täydellä kuormalla, saraturve kantaa keskimäärin 21 vuorokautta myöhemmin. Liejumailla ero on vielä suurempi. Tulokset viittaavat siihen, että turvemaan alakategorioilla on suuri merkitys. Tulosten perusteella, pelkkä turvemaa käsitteenä on liian yksinkertainen korjuukelpoisuutta määriteltäessä. Vielä parempi olisi, jos olennaisimpia maaparametrejä voisi mitata tai arvioida tarkemmin. Maalajiparametrien arvoissa on syytä epäillä, että niissä on vaihteluväli ja jakauma. Kuormatraktorin kuorman massalla on olennainen vaikutus maan kantavuuteen. Mitä heikommin kantava maalaji on kyseessä, sitä hitaammin sen kantavuus kehittyy pakkasmäärän kasvaessa.

Vertailuissa paljastui, että paras yhtäläisyys löytyi, kun kolme heikoimmin kantavaa luokkaa vertailtiin talvimaalajeihin. päällekkäisyys pinta-alaltaan oli 62% . Voidaan väittää, että korjuukelpoisuusmalli on pinta-aloiltaan kriittisempi korjuukelpoisuutta/kantavuutta määriteltäessä. Talvimaalajien ulkopuolisia KKL alueita oli huomattavasti enemmän, kuin toisin päin. Suurin osa näistä kuului Korjuukelpoisuusmallin ”talvi” luokkaan. Nämä alueet ovat maalajimallin mukaan kantavia karkeampia kivennäismaita. Erinäiset seikat, kuten korkea kosteusindeksi ja vähäpuustoisuus ovat voineet puoltaa luokittelun talvi- luokkaan. Tämä voi olla perusteltua, sillä kosteudella on suuri vaikutus myös kivennäismaiden kantavuuteen.

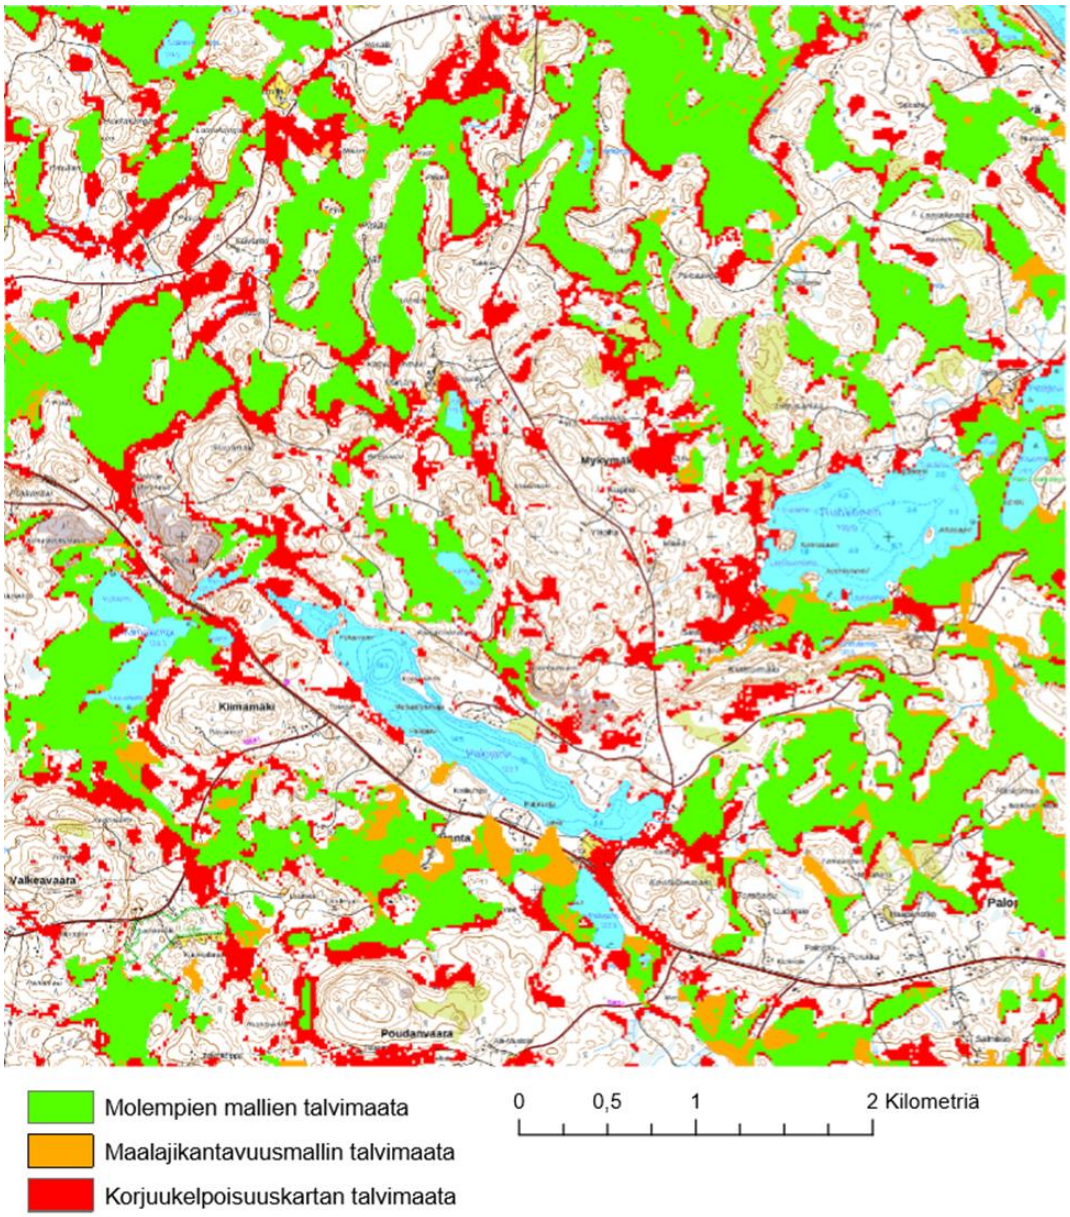

Kuva 3. *Talvimaalajien ja korjuukelpoisuuskartan yhtäläisyys koealueella. Korjuukelpoisuuskartan valitut luokat ovat ”talvi”, ”kuiva kesä turvemaa” ja ”normaali kesä turvemaa” (paras yhtäläisyys). Vihreä kuvastaa, missä mallit menevät päällekkäin (vastaavat toisiaan). Oranssi ja punainen ovat alueita, joissa vain toinen vaihtoehdoista toteutuu. Vihreän osuus 62%.*

3.4. Kaukokartoituksella saatavan informaation lisäarvo (TP4)

3.4.1. Kivisyyden ennustus (UEF)

Hankkeessa kehitettiin kolme eri menetelmää/mallia kivien tunnistamiseksi laseraineistosta (Vänttinen 2017) ja niiden parametrejä testattiin monikanava-lidar aineistolla. Uusimmassa aineistossa mitattiin kaiken kaikkiaan mittauskohteita 592 Liperistä, Pohjois-Karjalasta (Vänttinen 2019).

Menetelmässä pyrittiin tunnistamaan tietyssä 3D korkeusvyöhykkeessä olevien lidar-pisteiden aukkoisuus. Luomalla vyöhykkeet valikoitujen lidar-pisteiden ympärille, oletettiin kivien, pensaiden ja puiden muodostamat aukot erottuvan aukkoina. Sopivalla vyöhyke-koolla pensaiden ja puiden jättämät aukot katoaisivat oletuksella, että osa kaiuista pääsisi latvuston läpi maahan asti. Tällöin isommat kivet jäisivät näkyviin. Lisäksi suodatettiin myös korkeammat puut pois valikoimalla sekä alle 0,5 että yli viiden metrin pisteet. Lopuksi aukkoja muodostivat vain puuttuvat 0,5 ja viiden metrin väliin jääneet kivien, pensaiden ja pienten puiden aiheuttamat pisteet. Kriteerinä käytettiin myös monikanavakeilaimen väri-infrakanavan värisävyä.

Käytettyjen mallien parametrit testiaineistossa:

- Malli 1: 0.4 < h < 4m, värisävy > 45
- Malli 2: värisävy > 45
- Malli 3: 0.4 < h < 4m, värisävy > 45, vyöhyke 30 cm

Yhteenvetona voidaan todeta, että ”Malli2” tunnisti kohteita eniten. ”Malli3” tunnisti eniten kiviä/kivikasoja. ”Malli1” tunnisti kohteita selkeästi vähiten, mutta ei sortunut yhteenkään virhehavaintoon. Kun verrataan mallin kaikkia havaintoja ja toivottuja kivi/kivikasa havaintoja, ”Malli1” oli luotettavuudeltaan paras.

Malli	Havaittu	Kivi/Kivikasa	Onnistumisprosentti (%)
Malli1	63	63	100,0
Malli2	263	213	81,0
Malli3	240	226	94,2

”Malli1” havaitsi vain suurimpia kiviä. Keskiarvoltaan ja keskialarajaltaan muut mallit kykenivät havaitsemaan keskiarvoisesti noin metrin kapeampia ja puoli metriä matalampia kiviä. ”Malli1” voisi löytää riittävän pieniä kiviä vielä maastotietokannan tarkkuusvaatimuksissa, mutta hakkuukoneen reittisuunnittelu vaatisi vähintään metrin ja mieluummin puolen metrin korkuisten kivien löytämisen. Malli1 löysi kiviä harvemmin alle metrin korkeudelta tai puolentoista metrin leveydeltä. Pienimmillään Malli1 löysi hieman alle metrin korkeita ja leveitä kiviä. Mallien 2 ja 3 keskiarvot ja minimiarvot ovat kutakuinkin samat, mutta keskialarajat ovat mallilla2 noin 10-20 senttimetriä matalampia kuin Mallilla3. Malli2 löysi kiviä harvemmin alle puolen metrin korkeudesta ja 60 senttimetrin leveydestä. Malli3 löysi harvemmin alle 60 senttimetrin korkeudesta ja 70 senttimetrin leveydestä. Mikäli tavoitteena on hakkuukoneen reittisuunnittelu mallin1 tarkkuus ei riitä mutta mallit 2 ja 3 voisivat paranneltuna riittääkin.

Kivet/Kivikasat		Läpimitan (m)		Korkeuden (m)		
Malli	Keskiarvo	Keskialaraja	Minimi	Keskiarvo	Keskialaraja	Minimi
Malli1	3,3	1,7	0,9	2,0	1,1	0,8
Malli2	2,2	0,7	0,4	1,4	0,5	0,5
Malli3	2,2	0,9	0,5	1,4	0,7	0,4

Malli1 jätti havaitsematta keskimääräisesti 40 senttimetriä leveämpiä ja 20 senttimetriä korkeampia kiviä. Yleisesti metriä korkeammat havaitsemattomat kivet eivät olisi hakkuukoneen reittisuunnittelun kannalta hyväksyttäviä. Malli1 jättää kiviä enimmäisleveydeltään keskimäärin kahden ja kolmen metrin väliltä jo enimmäiskorkeudeltaan noin yhden ja puolentoista metrin väliltä. Mallit 2 ja 3 jättivät leveydeltään saman kokoluokan kiviä ja korkeudeltaan malli3 keskimäärin noin kymmenen senttimetriä mallia 2 korkeampia. Kaiken kaikkiaan mallien 2 ja 3 jättämät kivet ovat samaa kokoluokkaa. Yleisesti yli kaksi metriä leveämpiä tai metrin korkeampia kiviä ei jää.

Ei näy	Läpimitan (m)		Korkeuden (m)			
Malli	Keskiarvo	Keskiyläraja	Maksimi	Keskiarvo	Keskiyläraja	Maksimi
Malli1	1,4	2,3	9,0	0,9	1,2	2,1
Malli2	1,2	1,8	4,1	0,7	0,9	1,2
Malli3	1,2	1,7	4,1	0,8	1,0	1,9

Kaiken kaikkiaan mallin 1 hyväksymisraja kulkee leveyden puolesta 1,7 ja 2,3 metrin välillä sekä korkeudessa 1,1 ja 1,2 metrin välillä mikä ei riitä. Mallin 2 vastaava raja on leveydessä 0,7 – 1,8 metriä ja korkeudessa 0,5 – 0,9 metriä sekä mallin 3 raja 0,9 – 1,7 metriä leveydessä ja 0,7 – yhden metriä korkeudessa. Viimekädessä mallit 2 ja 3 saavat kutakuinkin samoja arvoja.

3.4.2 Maan vesipitoisuus ja kantavuus

Geologian tutkimuskeskus (GTK) tutki maan vesipitoisuuden ja kantavuuden välistä yhteyttä Vihdin (N 60°24,480' ja E 24°23,134') kokeessa. Urapainuma ja maan vesipitoisuus määritettiin kokeen aikana 18-19.5.2016 ja toistettiin 6-7.6.2018. Toistomittauksilla haluttiin verifioida vesipitoisuuden spatiaalisten rakenteiden pysyvyys – puhutaan ns. aika-stabiliteetista (Sutinen et al. 2007). Vesipitoisuus mitattiin toukokuussa 2016 dielektrisesti kapasitanssisondilla (Percometer, Adek Ltd., Tallin, Estonia; Sirén at al. 2019) ja RSAD-tutkalla. Kesäkuussa 2018 vesipitoisuus mitattiin sekä kapasitanssisondilla että kannettavalla gammaspektrometrillä (RS-230 BGO Super-Spec Gamma spectrometer, Radiation Solutions Inc.; Markovaara-Koivisto et al. 2019).

Molemmat mittauskampanjat antoivat saman tuloksen – **maan vesipitoisuus selittää urapainuman/kantavuuden**. Vuonna 2016 vesipitoisuus (kapasitiivinen) korreloi (0.584) urapainuman kanssa (Sirén ym. 2019) ja vastaavasti vuonna 2018 (kapasitiivinen) (0.702) ja radiometrinen (0.688) korreloi urapainuman kanssa (Markovaara-Koivisto ym. 2019). Tämä siitäkin huolimatta, että mittaukset 18-19 toukokuuta, 2016 tapahtuivat lumensulamisen

jälkeen ja kesäkuun 6-7 päivän mittauksia 2018 edelsi poikkeuksellinen kuivuus. Vuona 2018 maksimipäivälämpötila (>20°C) saavutettiin 20 päivänä 31:stä ja edellinen sade 3. toukokuuta oli 33 päivää ennen mittauksia. Kun vertailtiin vuosien 2016 ja 2018 (kapasitiivisia) vesipitoisuuksia, näiden välinen korrelaatio oli 0.953. Tämä vesipitoisuuden aika-stabiliteetti (Sutinen ym. 2007) tarkoittaa sitä, että (stationaarinen) kantavuusluokittelu voidaan tehdä läpi Suoimen käyttäen GTK:n radiometristä lentoaineistoa. On huomattavaa, että vuoden 2016 kampanjan tuloksena myös oli, että maalaji on huono urasyvyyden selittäjä (Sirén ym. 2019).

3.5 Metsävara- ja olosuhdetiedon kartoitus omavalvonnan yhteydessä (TP5)

3.5.1. Kivisyyden määrittäminen mätästyksen yhteydessä (Metsäteho & Tampereen yliopisto)

Metsäteho ja Tampereen yliopisto (TAU) kehittivät menetelmän kivisyysluokan automaattiseen määrittämiseen mätästystyön yhteydessä. Tutkimus on osa Lari Melanderin väitöstutkimusta. Menetelmässä mätästyksen tekevän kaivinkoneen puomiin, lähelle kauhaa, kiinnitetään inertianmittausyksikö (inertial measurement unit, IMU) ja satelliittipaikannin (esim. GPS, GLONASS). Tavoitteena on luokitella kivisyys kolmeen luokkaan: vähäkiviseen (kivisyysindeksit 0-30%), keskikiviseen (40-60%) ja erittäin kiviseen (70-100%). Menetelmässä kaivinkoneen kauhasta mitatun värähtelyn oletetaan jollakin tavalla korreloivan alueen kivisyyden kanssa. Tutkimuksessa mittaukset tallennettiin mittalaitteeseen ja niistä opetettiin myöhemmin kivisyysluokkaa ennustava malli.

Tutkimuksessa mitattiin kauhan värähtelyä neljällä mätästystyömaalla. Työmailta mitattiin myös kivisyysindeksejä manuaalisesti kivisyysrassilla ja mitatut indeksit jaettiin kolmeen kivisyysluokkaan. Manuaalimittauksien mukaiset luokat yleistettiin kattamaan 8 metrin säteinen alue mittauksen keskikohdasta. Manuaalimittauksilla saatu tieto alueen kivisyydestä yhdistettiin paikannetun ja ikkunoidun värähtelydatan kanssa. Yhdistetyllä tietoaineistolla opetettiin ohjatun oppimisen periaatteella toimivia koneoppimisalgoritmeja luokittelemaan värähtelydataa kivisyysluokkiin.

Valmiilla mallilla voidaan ennustaa kivisyysluokka jokaiselle aikaikkunalle värähtelydatassa. Tämä luo paljon pistemäisiä ennustuksia jo yhtä mätästä kohden, joten tutkimuksessa käytettiin 16m×16m hilasolua ennustusten yhdistämiseksi. Hilasolun luokka määräytyy solun sisällä eniten ennustetun luokan mukaan. Näin saadulla hilatason ennusteella voidaan tuottaa Kuvan 4 mukaisia kivisyyskarttoja mätästetyltä alueelta.

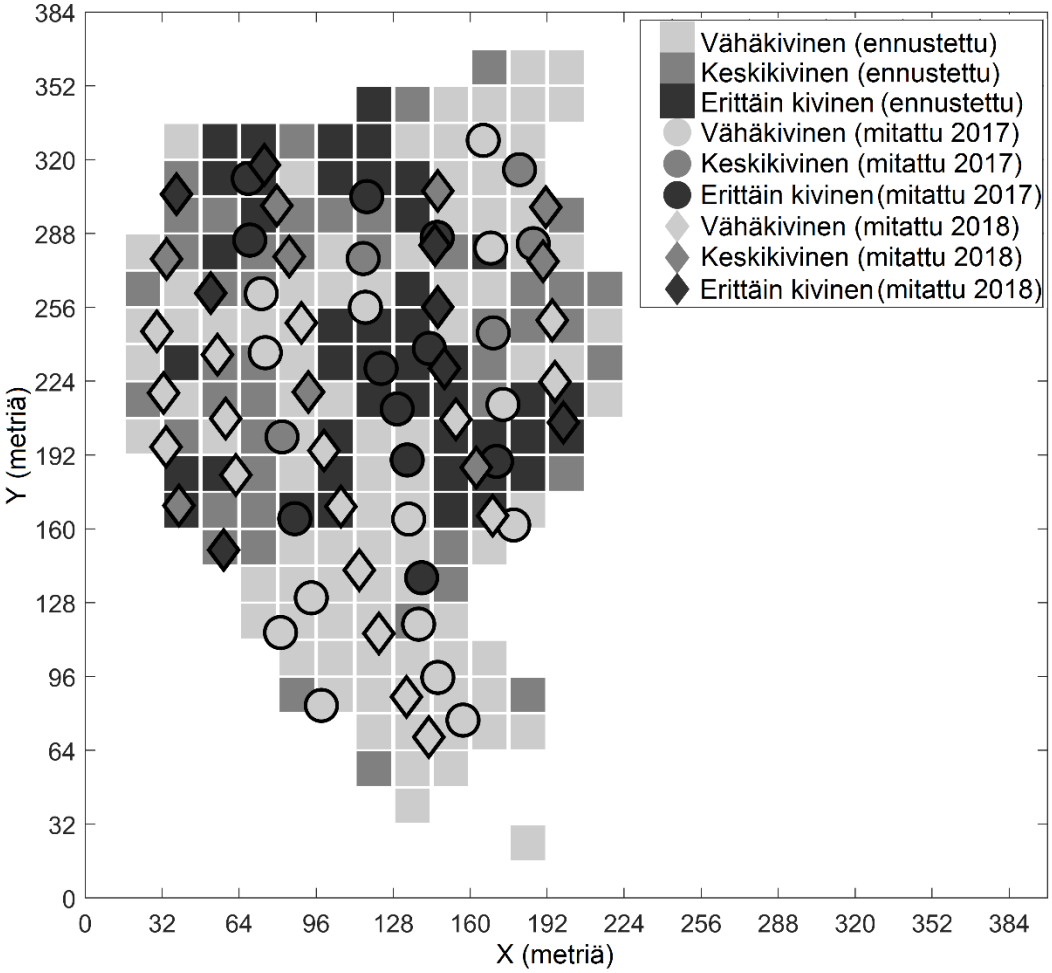

Kuva 4. *Ennustetut kivisyysluokat ja manuaalimittaukset yhdelle mätästystyömaalle (16m×16m hilasoluissa).*

Mukana olleet neljä työmaata olivat hyvin erilaisia. Kahdella työmaista kaikki kivisyysluokat olivat tasaisesti edustettuina, yhdellä oli pääasiassa matalaa kivisyyttä ja yhdessä paljon hyvin kivisiä osuuksia. Sama malli tuotti johdonmukaisia tuloksia kaikille työmaille ennustettaessa. Tuotetun mallin luokittelutarkkuutta on hankalaa arvioida, koska kivisyys vaihtelee todennäköisesti paljon manuaalimittausten ympäristössä ja mätästyskauhaisut eivät osu suoraan mitattuihin kohtiin. Tästä syystä tarkkuutta arvioitiin 16m×16m hilasoluille tehtyjen ennustusten ja manuaalimittausten osumistarkkuuden perusteella. Tällä tavoin laskettu tarkkuus oli noin 70%, kun käytettiin kolmea kivisyysluokkaa. Tarkkuutta voidaan pitää riittävänä metsänhoidollisiin tarpeisiin, ja kartat antavat ainakin mitatuilla työmailla varsin hyvän kuvan kohteen kivisyyden vaihteluista.

Käytännön sovelluksessa mitattuja värähtelyitä luokiteltaisiin valmiiksi opetetulla mallilla esimerkiksi yhden mätästystyömaan ajon jälkeen. Menetelmällä voitaisiin siten tuottaa suuri määrä kivisyystietoa vain pienillä teknisillä ja kohtuullisen halvoilla lisäyksillä mätästystyötä tekeviin kaivinkoneisiin. Menetelmän jatkokehittely ja verifiointi vaativat kuitenkin lisää mitattua dataa erilaisilta työmailta ja erilaisista olosuhteista. Projektin tulokset esitellään julkaisussa (Melander ym. 2019).

3.5.2. Maalajin tunnistaminen kuvasta (Metsäteho & Tampereen yliopisto)

Metsäteho kuvasi laikkumätästyksen yhteydessä paljastunutta maanpintaan tavoitteena automaattisesti luokitella kohteen maalajia. Tampereen yliopisto auttoi Metsätehoa arvioimaan kuvien käytettävyyttä ja automaattisen luokittelun mahdollisuutta. Tavoitteena oli maalajien luokittelu kahteen isoon luokkaan: karkeat maalajit ja hienot maalajit. Kuva-aineistoon saatiin kerätyksi noin 1000 karkean maanlajin kuvaa ja alle 100 hienon maalajin kuvaa.

Maalajin tunnistus pelkän kuvan perusteella osoittautui haastavaksi. Asiantuntija määrittää maalajin käyttäen ulkonäön lisäksi maanäytteen ominaisuuksien tunnusteluun perustuvia havaintoja sekä yleisestä tietämystä alueen topografiasta. Tämän vuoksi automaattinen tunnistus pelkkien kuvien perusteella on hankala tehtävä myös oppivia algoritmeja hyödynnettäessä. Kerätty kuva-aineisto oli riittämätön ns. deep learning tyyppiseen oppimiseen, etenkin pienen hienojakoisten maalajien kuvamäärän takia. Perinteiset koneoppimismenetelmät vaativat kuvasta laskettavien piirteiden valintaa, jotta luokittelu voisi onnistua. Kerätyllä aineistolla ei löydetty tarpeeksi hyviä piirteitä tähän tarkoitukseen. Esimerkiksi pelkkä väri ei suoraan kerro kohteen maalajista ja otetut kuvat sisältävät paljon muutakin informaatiota kuin vain puhdasta maa-ainesta. Lisäksi kuvausolosuhteet mätästyksen yhteydessä eivät ole ikinä vakiot; etenkin valaistusolosuhteet ja maa-aineksen sen hetkinen kosteus vaikuttavat merkittävästi näytteen ulkonäköön kuvassa.

4 Tulosten arviointi – tulosten tieteellinen merkitys ja käytännön sovellettavuus

4.1 Metsäkoneen anturointi ja kulkukelpoisuus (TP1)

Hakkuukoneeseen voidaan rakentaa ilman merkittävää lisäanturointia järjestelmä, joka taltioi moottoritehon ja paikkatiedon 10 kertaa sekunnissa ja lähettää tiedon koostettuna hakkuukoneelta eteenpäin. Asia etenee parhaiten standardoinnin avulla, jonka jälkeen konevalmistajilla on hyvät edellytykset rakentaa omiin metsäkoneisiinsa tarvittavat tallennus, esikäsittely ja lähetysproseduurit.

Suosittelemme myös lisätutkimusta hakkuukoneen kiihtyvyysanturoinnin ja kaltevuusanturoinnin kytkemiseksi osaksi järjestelmää.

Metsäkoneen raiteen mittaus automaattisesti ajon aikana onnistuu periaatteellisella tasolla. Sen käytäntöön soveltamisessa on kolme merkittävää estettä. Ensiksi, laserkeilaimen suojaus täytyy pystyä tekemään integroidusti kuormatilan runkoon. Toiseksi, laserkeilaimet ovat suhteellisen kalliita komponentteja, joten järjestelmästä tulisi kohtuullisen kallis. Kolmanneksi, menetelmä kaipaisi runsaasti vielä tutkimus- ja kehittämispanostusta ennen kuin järjestelmä voidaan viedä käytäntöön.

4.2 Staattinen korjuukelpoisuusluokittelu (TP2) (Arbonaut, HY, Metsäteho)

Korjuukelpoisuuskartan luokituksen arviointi korjuuvauriomittausten perusteella osoitti, että luokitus on luotettava mutta hieman konservatiivinen, joka on käytännön toimenpiteiden

suunnittelun ja toteuttamisen kannalta hyvä lopputulos. Tulosten arvioinnissa tulee kuitenkin huomioida, että korjuuvaurioiden syntymiseen vaikuttavat monet sellaiset tekijät, joiden vaikutusta tässä kyseisessä tutkimuksessa ei huomioitu ja joita on haastavaa huomioida korjuukelpoisuuskartan kehittämisessä. Tällaisia tekijöitä ovat mm. käytettävien metsäkoneiden koko ja ominaisuudet (paino, telat jne.), havutuksen määrä sekä kuljettajan ammattitaito hakkuu-uran sijainnin suunnittelussa.

Käyttäjille suunnatun kyselytutkimuksen mukaan korjuukelpoisuuskartta koetaan hyödylliseksi ja tarpeelliseksi palveluksi, joka on vakiinnuttanut nopeasti asemansa korjuuoperaatioiden ohjaustyökalujen joukossa. Positiivinen käyttäjäkokemus on jo itsessään osoitus kartan soveltuvuudesta käytäntöön. Palautteissa esitettyihin toiveisiin kartan tarkkuuden edelleen kehittämisestä voitaneen vastata parhaiten sekä maaperäkartan että dynaamisen säätiedon hyödyntämisellä.

GTK:n maaperäkartan hyödyntäminen korjuukelpoisuusluokituksen parantamisessa osoittautui tutkimustulosten perusteella hyvin lupaavaksi jatkokehitysaskeleeksi. Saavutetun parannuksen määrää (10 ja 20 prosentin parannus oikeinluokitusprosentissa) voidaan pitää merkittävänä. Menetelmä voidaan ottaa käyttöön jo nykyisissä korjuukelpoisuuskartoissa lyhyessä ajassa, koska laskenta voidaan tehdä jälkilaskentana. Tutkimustulosten arvioinnissa tulee kuitenkin huomioida, että etenkin 1:20 000 aineiston tulokset perustuvat alle 300 koealahavaintoon. Laadittu malli ei siten ole välttämättä yleistettävissä. Aiheen tutkimista varten tulisikin kerätä lisää havaintoaineistoa 1:20 000 kartan alueelta ja tulokset validoida erillisellä validointia varten kerätyllä aineistolla ennen kuin menetelmä otetaan käyttöön julkaistavissa korjuukelpoisuuskartoissa.

4.3. Korjuukelpoisuusennusteiden kehittäminen olosuhdetiedon avulla (TP3)

4.3.1 Maaperän hydrologiset tunnukset (Luke)

Saadun tulokset saven ennustamiseksi topografia ja puustotiedon avulla ovat hyvin lupaavia. Menetelmää tulee testata riippumattomien aineistojen avulla. Testaus kannattaa liittää osaksi GTK:n koordinoimaa projektiehdotusta maalajikarttojen muodostamiseksi.

4.3.1 Maaperän hydrologiset tunnukset (Luke)

SpatFy-malli on erittäin lupaava sovellus, jolla voisi ajatella olevan valtavan paljon käyttöä metsäoperaatioita suunniteltaessa. Samalla malli on hyvin monimutkainen. Sitä ei välttämättä tässä muodossa kannata liittää osaksi puunkorjuun suunnittelujärjestelmää. Kyseinen Demo on erinomainen lähtökohta tiedon arvon testaamiselle sekä datarakenteiltaan käyttökelpoisempien dataratkaisujen luomiselle.

4.3.3 Dynaamiset kulkukelpoisuusennusteet (UEF)

Talvikorjuukauden tarkempaan ajoittamiseen liittyy epävarmuustekijöitä. Suomalainen epävakaa ilmasto takaa sen, että maaperän roudan muodostuminen, ja sitä kautta metsäkoneiden kantavuuden vaihteluväli on huomattava. Lisäksi roudan muodostuminen on paljon lumisateiden armoilla. Aikainen ja paksu lumisade takaa sen, että roudan muodostuminen kärsii. Mitä heikommin kantava metsämaa on kyseessä, ja mitkä suurempi

ajoneuvon pyörien aiheuttama paine on, sitä suurempaa vaihtelua kantavuuden päivämäärässä on. Kantavuuden ennustamisessa on realistisempaa käyttää todennäköisyyttä perustuen analyysissä käytettyihin 20 vuoden sääaineistoon. Korjuun ajoittamisesta vastaava henkilö voi tällöin perustaa vastauksensa siihen, miten hyvin hän sietää riskiä. Tulokset eivät olleet rohkaisevia sen suhteen, että maalajien kantavuus riippuisi selkeästi roudan muodostumisen alkamisajankohdasta. Toisaalta kun tarvittavan pakkasmäärä on alhaisempi, sitä vähemmän tuloksista havaitaan hajontaa, kuten tyhjän kuormatraktorin tuloksista huomataan.

Jotta sääaineistoa voisi realistisemmin käyttää esimerkiksi korjuun tarkassa ajoittamisessa, voidaan muodostaa laskuri, jolla nykytiedot otetaan huomioon kantavuuden arvioimisessa:

1: Syöttötiedot: päivämäärä, nykypäivän pakkasmäärä, lumen syvyys (esim. 10.joulukuuta, pakkasmäärä 1000, lumen syvyys 5cm)

2: Tarkista ylittyykö tarvittava pakkasmäärä kullekin maalajille nykyisellä pakkasmäärällä

3: Laske pakkasmäärä muutos (+/-) jokaiselle vuorokaudelle aineiston 20 vuodelle (ilman lumikerrointa)

4: Laske pakkasmäärän muutos (+/-) esim. tulevalle viikolle ja kahdelle viikolle.

5: laske lumen syvyyden kasvu samalla tavalla kuin pakkasmäärän muutos haluttaville aikaväleille

6: painota pakkasmäärän muutos lumikertoimella ja lumen syvyyden muutoksella

7: Laske miten monena vuotena maalaji kantaa 1 ja 2 viikon kuluttua (nykytilan pakkasmäärä + 1 ja/tai 2 viikon aikana kerääntyvä pakkasmäärä)

8: laske todennäköisyys (yksi vuosi vastaa 5% todennäköisyyttä 20 vuoden aineistosta)

Tulos: Näyttö sille, että kantavatko mitkäkin maalajit millä todennäköisyydellä 1 ja 2 viikon kuluttua perustuen viimeiseen 20 vuoden sääaineistoon.

Kantavuuden ennustamisessa voidaan käyttää myös tukena säätiedotusta varmemman tuloksen saavuttamiseksi. Nykytilan hyödyntämistä kantavuuden arvioimisessa on hyvin kannattavaa käyttää hyväksi, koska jo marraskuun puolella pakkasmäärässä on havaittavissa selviä muutoksia.

4.4. Kaukokartoituksella saatavan informaation lisäarvo (TP4)

4.4.1. Kivisyyden ennustus (UEF)

Hakkuukoneen esteen ylityskyky vaihtelee eri olosuhteissa. Mikäli molemmat eturenkaat pääsevät ajamaan kiven päälle, ylityskyky on tyypillisesti noin metri. Tällöin oletuksena on, että sivuttaista kaltevuutta ei ole ja kivi on koneen levyinen ja yhtä korkealla maanpintaan nähden molempien eturenkaiden alla. Kokonaisuudessa on kuitenkin huomioitava kiven muoto ja pituus sekä kiven jälkeen jatkuvan maaston korkeuden suhde kiven korkeuteen. Hakkuukoneen maavara on noin 50-60 senttimetriä. Pohjakosketuksen riskinä ovat myös

kivet jotka ylittävät maavaran eikä yli ajavan hakkuukoneen kumpikaan rengas aina nouse kunnolla kiven päälle. Hakkuukoneen reittisuunnitteluun soveltuvan mallin pitäisi kyetä löytämään vähintään hakkuukoneen ajoa estävät metrin korkeat kivet ja mielellään myös maavaran ylittävät 50 senttimetriä korkeat kivet.

Hankkeessa arvioitiin eri menetelmien mahdollisuuksia tunnistaa kiviä ja kivikoita. Menetelmien luotettavuus oli kohtuullisen hyvä. Kohteiden pinnan vaikutus kiven näkyvyyteen oli miltei sama kaikissa malleissa. Yleisesti kiven osuus edisti hieman kivien näkyvyyttä mutta samoin toimi syystä tai toisesta kasvillisuus ja puusto. Maan osuus kivien pintamateriaalina oli kaiken kaikkiaan hyvin vähäinen ja sammalta esiintyi lähes kaikkialla kiven näkyvyydestä riippumatta. Näkyvyyteen vaikuttaa ennen kaikkea kiven koko. Yleisesti ottaen suuremmat kivet näkyivät aina pienempiä paremmin mallista riippumatta. Koska kohteet tunnistettiin parhaimmillaan erinomaisesti, voidaan arvioida, että lidar tulkinnalla voidaan tunnistaa maastonavigointia vaikeuttavat kivet ja kohteet. Hankkeen tulokset ovat kuitenkin alustavia ja vaativat tarkennusta operatiivisessa ympäristössä.

4.4.2. Kantavuuden ennustaminen (GTK)

Vihdin koe osoitti, että urasyvyys/kantavuus voidaan ennustaa maan vesipitoisuuden perusteella (Sirén ym. 2019; Markovaara-Koivisto ym. 2019). Maalajin todettiin ennustavan huonosti urasyvyyttä. Tämä paljolti johtuu siitä, että laboratoriomäärityksissä maanäytteistä leikataan, laboratoriosta riippuen, yli 6 mm ja/tai 20 mm fraktiot pois analyyseistä. Useimmiten kuitenkin ohivirtausreitit ovat juuri karkeassa fraktiossa ja sen takia vesipitoisuuden estimointi maalajin perusteella ei onnistu (Sutinen ym. 2007). On myös muistettava, että maalajikartoitus on lopetettu Suomessa.

Vihdin koe osoitti, että *in situ* radiometrinen (gamma) vesipitoisuus ennusti erittäin merkitsevästi urasyvyyden/kantavuuden (Markovaara-Koivisto ym. 2019). Myös Mattila & Tokola (2019) ovat tulleet samansuuntaiseen päätelmään käyttäen GTK:n lentoaineistoa. GTK:n radiometrinen (gamma) lentoaineisto, kattaen koko maan ja interpoloituna 50x50 m:n hilaan, on avainasemassa kantavuuden stationaarisissa malleissa. Dynaamisilla malleilla, perustuen maaprofiilien dielektriseen monitorointiin (e.g. Sutinen ym. 2007) ja dielektrisiin (nopeat kertamittaukset) referensseihin (Markovaara-Koivisto ym. 2019), parannetaan kantavuusestimaattien ajallista tarkkuutta.

4.5 Metsävara- ja olosuhdetiedon kartoitus omavalvonnan yhteydessä (TP5)

4.5.1. Kivisyysluokan määrittäminen mätästyksen yhteydessä (Metsäteho & TAU)

Laikkumätästystä tekevään kaivinkoneeseen voidaan rakentaa halpa anturointijärjestelmä, joka tuottaa kivisyysarvioita koneen mätästämiltä alueilta. Tutkimuksessa selvitettiin, että edellytykset kivisyyden ennustamiselle värinädatan pohjalta ovat olemassa. Menetelmän soveltaminen vaatii kuitenkin paljon jatkokehitystä. Kivisyydataa pitäisi kerätä useammalta työmaalta, jotta kuljettajan, sään ja kohteen vaikutukset mittaukselle saadaan otettua huomioon tuotetussa mallissa. Lisäksi kaivinkoneeseen asennettavan järjestelmän on pystyttävä tallentamaan mitattua värinää tai siitä jalostettua kivisyysluokkaa automaattisesti

esimerkiksi pilvipalveluun. Lisätutkimusta voitaisiin tehdä järjestelmällä, joka ottaa kaivinkoneen hydraulisylinterien paineet huomioon luokittelua tehdessä.

Kehitettyä menetelmää voitaisiin hyödyntää kivisyyden kartoituksessa metsänkäsittelyketjun seuraavia vaiheita varten sekä referenssitiedon tuotannossa esimerkiksi mallinnukseen tai kaukokartoitukseen perustuville kivisyyden ennustamismenetelmille.

4.5.2. Maalajin tunnistaminen mätästyksessä (Metsäteho & TAU)

Maalajin tunnistus kuvasta osoittautui haastavaksi. Ajatuksena oli, että esimerkiksi korjuu- tai maanmuokkaukseen yhdistetyllä maalajitunnistuksella voitaisiin tuottaa tehokkaasti maalajitietoa käsittelyketjun seuraaviin päätöstilanteisiin, referenssidataa maaperätunnusten ennustamiseen sekä tukiaineistoa kantavuusmallien evaluointiin ja kehittämiseen. Menetelmä saattaa olla mahdollinen, mutta standardoitua ja luokiteltua kuva-aineistoa pitäisi kerätä todella paljon enemmän. Muiden tietolähteiden käyttö ja yhdistely, joko kuvadatan kanssa tai ilman, saattaisi tuottaa parempia tuloksia maalajin tunnistamisessa.

5 Julkaisut

Tieteelliset artikkelit

Ala-Ilomäki Jari, Salmivaara Aura, Launiainen Samuli, Lindeman Harri, Kulju Sampo, Finér Leena, Heikkonen Jukka and Uusitalo Jori. 2019. Assessing extraction trail trafficability using forest harvester CAN-bus data. Submitted manuscript.

Heiskanen J, Hallikainen V, Salmivaara A, Uusitalo J, Ilvesniemi H. 2019. Predictive models for soil fine fraction and organic matter in Finnish upland forests from readily available soil and terrain data. Manuscript submitted to Geoderma.

Heiskanen J, Hallikainen V, Uusitalo J, Ilvesniemi H. 2018. Co-variation relations of physical soil properties and site characteristics of finnish upland forests. Silva Fenn 52:articel id 9948. 18 p. doi: 10.14214/sf.9948

Kankare, V., Luoma, V., Saarinen, N., Peuhkurinen, J., Holopainen, M., Vastaranta, M. Assessing feasibility of the forest trafficability map for avoiding rutting - a case study. 2019. Silva Fennica Research note [Manuscript submitted 13. May 2019]

Markovaara-Koivisto, M., Sirén, M., Hänninen, P., Palmi, J-P., Ala-Ilomäki, J., Lindeman, H., Sutinen, R. 2019. Dielectric and radiometric evaluation of time-stability of soil water content and forwarding rut deformation. Manuscript to be submitted to Soil and Tillage Research.

Mattila, U. & Tokola, T. 2019. Terrain mobility estimation using TWI and airborne gamma-ray data. Journal of Environmental Management 232. 531-536 s.

Melander L & Ritala R (2018) Time-of-flight imaging for assessing soil deformations and

improving forestry vehicle tracking accuracy, International Journal of Forest Engineering, 29:2, 63-73, doi: 10.1080/14942119.2018.1421341

Melander L, Ritala R, Strandström M. 2019. Classifying soil stoniness based on the excavator boom vibration data in mounding operations. Manuscript submitted to Silva Fennica.

Niemi, M.T., Vastaranta, M., Vauhkonen, J. & Holopainen, M. 2017. Airborne LiDAR-derived elevation data in terrain trafficability mapping. DOI: 10.1080/02827581.2017.1296181

Salmivaara, A., Miettinen, M., Finér, L., Launiainen, S., Korpunen, H., Tuominen, S., Heikkonen, J.. Nevalainen, P., Sirén, M., Ala-Ilomäki, J. & Uusitalo J. 2018. Wheel rut measurements by forest machine-mounted LiDAR sensors – accuracy and potential for operational applications. Int J For Eng 0–12. doi: 10.1080/14942119.2018.1419677

Sirén, M., Salmivaara, A., Ala-Ilomäki, J., Launiainen, S., Lindeman, L., Uusitalo, J., Sutinen, R., Hänninen, P. 2019. Predictive factors for forwarding rut formation on fine-grained soils. Scandinavian Journal of Forest Research. https://doi.org/10.1080/02827581.2018.1562567

Sutinen, R., Middleton, M., Hänninen, P., Vartiainen, S., Venäläinen, A., Sutinen, M.- L., 2007. Dielectric constant time stability of glacial till at a clear-cut site. Geoderma 141, 311–319.

Konferenssijulkaisut

Jari Ala-Ilomäki, Aura Salmivaara, Samuli Launiainen, Harri Lindeman, Jori Uusitalo and Leena Finér. Harvester CAN-bus data for site trafficability mapping. 2017. IUFRO 125th Anniversary Congress Freiburg, Germany, Sept 18-22, 2017. http://iufro2017.com/wp-content/uploads/2017/09/AbstractIUFRO17_III.pdf

Muut julkaisut

Ala-Ilomäki, Jari; Väätäinen, Kari; Piri, Tuula; Asikainen, Antti; Muhonen, Timo; Isto, Pekka; Leinonen, Anne. 2017. Digitaaliset ratkaisut puun tehokkaampaan hyödyntämiseen . Julkaisussa: Bittejä ja biomassaa : Tiekartta digitalisaation vauhdittamaan biotalouteen, VTT Visions 11, s. 2-9. URL: http://www.vtt.fi/inf/pdf/visions/2017/V11.pdf http://urn.fi/URN:ISBN:978-951-38-8605-9

Leena Finér, Aura Salmivaara, Jari Ala-Ilomäki, Samuli Launiainen, Sakari Tuominen, Sampo Kulju, Ari Laurén, Jori Uusitalo, Matti Sirén, Paavo Nevalainen, Tapio Pahikkala, Jukka Heikkonen. 2017. Maaston kantavuuden ennustemalleja puunkorjuun tarpeisiin - Modeling forest terrain trafficability for wood procurement FOTETRAF ja MEOLO projects. Geoinformatikan päivät, Helsinki 4.-5.52017.

Ovaskainen, H (toim.). 2019. Kohti automaattista puunkorjuun laadun mittaamista. Metsätehon raportti 251. http://www.metsateho.fi/kohti-automaattista-puunkorjuun-laadun-mittaamista/

Lehtiartikkelit

Jokela, A ja Sirén, M. 2017. Monilähdetiedolla eväitä ympärivuotiseen korjuuseen. Maaseudun tulevaisuus 16.10.2017

Ala-Ilomäki, J. 2017. Teknologialoikka metsäluonnon hyväksi. Maaseudun tulevaisuus 16.10.2017, s. 15.

Opinnäytteet:

Kärkkäinen, Esa. 2017. Metsäkuormatraktorin ajourapainaumien ennustus ja vierintävastuksen analysointi ajotietokoneiden perusteella. Itä-Suomen yliopisto, Luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto. Metsätieteen kandidaatin tutkielma. 25 s.

Kärkkäinen, Esa. 2019. Talvikorjuukelpoisuuden dynaaminen ennustaminen ja staattiseen korjuukelpoisuusluokitukseen vertaaminen. Itä-Suomen yliopisto, Luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto. Metsätieteen pro gradu. 35.s.

Vänttinen, M. 2017. Kivisyyden tunnistaminen laserkeilausaineistosta. Itä-Suomen yliopisto, Luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto. Metsätieteen kandidaatin tutkielma. 33 s.

Vänttinen, M. 2019. Kivisyyden tunnistaminen laserkeilausaineistosta. Itä-Suomen yliopisto, Luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto. Metsätieteen pro gradu tutkielman käsikirjoitus.