

UNIVERSITY OF
EASTERN FINLAND

*Luonnontieteiden ja metsätieteiden
tiedekunta
Faculty of Science and Forestry*

LENTOLASERKEILAUKSEEN PERUSTUVIEN PUUTASON MALLIEN SIIRRETTÄVYYS
INVENTOINTIALUEIDEN VÄLILLÄ

Tomi Karjalainen

METSÄTIETEEN PRO GRADU,
ERIKOISTUMISALA METSÄNARVIOINTI JA METSÄSUUNNITTELU

JOENSUU 2017

Karjalainen, Tomi. 2017. Lentolaserkeilaukseen perustuvien puutason mallien siirrettävyys inventointialueiden välillä. Itä-Suomen yliopisto, luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto. Metsätieteen pro gradu, erikoistumisala metsänarviointi ja metsäsuunnittelu. 71 s.

TIIVISTELMÄ

Noin viimeisen vuosikymmenen aikana erilaiset laserkeilaukseen pohjautuvat menetelmät ovat Suomessa nousseet vallitseviksi menetelmiksi metsäinventoinnissa sekä paremman tarkkuustasonsa että halvempien kokonaiskustannustensa ansiosta. Vaikka menetelmät ovat kehittyneet nopeasti, tarvitaan laserkeilauspohjaisen inventoinnin tueksi kuitenkin edelleen varsin suuri määrä maastosta mitattuja koealoja, joiden mittaaminen on aikaa vievää ja muodostaa varsin suuren osuuden inventoinnin kokonaiskustannuksista.

Yksi keino maastomittausten vähentämiseksi olisikin käyttää eri aineistojen pohjalta laadittuja malleja (esim. pituus, tilavuus) toisilla inventointialueilla. Mallien siirtämisessä toiselle alueelle aiheutuu kuitenkin ongelmia, sillä inventointialueet poikkeavat toisistaan yleensä niin puuston kuin laserkeilauksen yksityiskohtienkin puolesta. Ennusteiden epätarkentuminen siirron yhteydessä on siis käytännössä väistämätöntä, mutta toisaalta heikentyminen voi olla vain vähäistä ja siten asetetusta tarkkuusvaatimuksesta riippuen mahdollisesti myös merkityksetöntäkin.

Tämän tutkimuksen tavoitteena oli tutkia, kuinka paljon laserkeilauksen yksinpuintulkinta-lähestymistavalla luodut puutason ennusteet epätarkentuvat, kun käytetyt mallinnus- ja kohdeaineistot ovat täysin erillisiä. Tarkastelu kohdistettiin pelkästään rinnankorkeusläpimitaltaan > 16 cm mäntyihin, joita oli lopullisessa mallitusaineistossa Liperissä 1051 kpl, ja kohdealueilla Kiihtelysvaarassa 414 kpl ja Kolilla 317 kpl. Kukin tutkimuspuu eroteltiin latvuston korkeusmalista omaksi segmentikseen, ja näihin segmentteihin osuneista laserkeilauspulsseista laskettiin ko. puuta kuvaavia tunnuksia. Lopulta puille ennustettiin läpimitta, pituus, latvusraja, rungon kokonaistilavuus sekä teoreettinen tukkitilavuus käyttäen sekä lähimmän naapurin menetelmää että lineaarisia regressiomalleja.

Siirtojen aiheuttaman epätarkentumisen selvittämiseksi laskettiin ensin ennusteiden tarkkuus eli suhteelliset RMSE-arvot mallitusdatassa. Saatuihin arvoihin verrattiin sitten kohdealueilla saavutettuja vastaavia arvoja. Saavutetut tulokset olivat odotettuja, eli kaikki ennusteet heikkenivät siirtojen yhteydessä. Lisäksi ennusteiden heikkeneminen vaihteli käytetystä menetelmästä ja kohdealueesta riippuen. Mallitusdataan verrattuna suhteelliset RMSE:t kasvoivat siirron yhteydessä pienimmillään seuraavasti: läpimitta 12,71 → 13,89 %, pituus 2,97 → 5,99 %, latvusraja 12,01 → 13,16 %, kokonaistilavuus 25,34 → 34,39 % ja tukkitilavuus 34,24 → 47,1 %. Vaikka esim. pituusenusteiden tarkkuus heikkeni yleisesti noin puoleen, oli kohdealueilla saavutetut n. 6 % RMSE-arvot silti melko hyviä.

Tutkimus osoitti, että yksinpuintason mallien siirtäminen on mahdollista ilman suurta/liiallista ennusteiden epätarkentumista, kunhan käytettävät keilausaineistot ovat keskenään melko samankaltaisia ja käytettävä mallitusdata kattaa puustoltaan kohdealueilla havaitun vaihtelun.

Avainsanat: ALS, yksinpuintulkinta, k-MSN, lineaarinen regressioanalyysi, siirrettävyys

Karjalainen, Tomi. 2017. The transferability of ALS-based tree level models between different inventory areas. University of Eastern Finland, Faculty of Science and Forestry, School of Forest Sciences. Master's thesis in Forest Science specialization Forest Mensuration and Forest Planning. 71 p.

ABSTRACT

During the last decade, different Airborne Laser Scanning (ALS) based methods have become dominant in Finnish forest inventories. The advantages of ALS are both better accuracy obtained and lower expenses. Despite the rapid evolution of different ALS methods, a lot of time consuming and expensive field measurements are still needed for reliable results.

One way to decrease the amount of field work is to use models that are originally constructed on entirely another inventory area. These models can predict for example mean height, volume etc. Most obviously, the cross usage of models leads to problems, since the inventory areas have different forest structure and also the laser scanning procedures have usually been executed with different parameter settings. Therefore, the degradation of the accuracy is inevitable, but if it is small enough it can still be insignificant and acceptable, at least from the practical point of view.

The aim of this study was to examine, the decrease of the accuracy of different ALS based models created with Individual Tree Detection method, when the models are applied in totally different inventory areas. Only Scots pines with diameter at breast height greater than 16 cm were considered. The modeling data in Liperi consisted of 1051 trees, and the target areas in Kiihtelysvaara and Koli had 414 and 317 trees, respectively. The geographical distance between these different areas was less than 100 km. Each of the studied pines were separated into their own segments from the canopy height models, and different ALS variables were calculated from all the pulses that had hit these segments. Finally, for each tree, diameter, height, crown base height, total volume and theoretical saw-log volume were predicted with both nearest neighbor method and linear regression models.

To examine the influence of transferring the models, the relative RMSE values were calculated for each method-area combination. The results were more or less as expected, since in all cases the accuracies observed were weaker in the target areas. Additionally, the amount of weakening varied with different method-area combinations used. The smallest increase of the relative RMSEs observed were following: diameter 12,71 → 13,89 %, height 2,97 → 5,99 %, crown base height 12,01 → 13,16 %, total stem volume 25,34 → 34,39 % and saw-log volume 34,24 → 47,1 %. Even though for example the height predictions had only about half of the original accuracy, the final RMSE values were still quite good being about 6 % in both target areas.

This study proved that it is possible to cross-use ALS-based single tree models on different inventory areas without excessively large reduction in accuracy. The used ALS materials just have to be somewhat homogenous between the areas, and also the modeling dataset should cover all the variation of individual trees that is observed on the target areas.

Keywords: ALS, individual tree detection, ITD, k-MSN, linear regression analysis, transferability

SISÄLLYS

TIIVISTELMÄ.....	2
ABSTRACT	3
1 JOHDANTO.....	6
1.1 Lentolaserkeilaus metsävaratiedon hankinnassa	6
1.2 Yleisimpien puustotunnusten ennustaminen ALS-informaatiosta.....	9
1.3 Laserkeilauspohjaisten puustotunnusmallien siirrettävyys	15
1.4 Tutkimuksen tavoitteet.....	19
2 AINEISTO JA MENETELMÄT	20
2.1 Maastomittaukset.....	21
2.2 Laserkeilaus.....	22
2.3 Latvuston korkeusmallit.....	23
2.4 Segmentointi ja yksinpuintulkinta	26
2.5 Koealaston lasertunnukset	29
2.6 Tilavuuden laskenta	29
2.7 k-Most Similar Neighbour –mallit (k-MSN).....	29
2.8 Lineaariset regressiomallit	30
2.9 Tarkkuuden arviointi.....	31
3 TULOKSET.....	32
3.1 k-MSN-menetelmä.....	32
3.1.1 Läpimitta	33
3.1.2 Pituus	34
3.1.3 Latvusraja.....	36
3.1.4 Kokonaistilavuus	37
3.1.5 Teoreettinen tukkitilavuus.....	39
3.2 Lineaariset regressiomallit	40

3.2.1 Läpimitta	41
3.2.2 Pituus	43
3.2.3 Latvusraja	45
3.2.4 Kokonaistilavuus	46
3.2.5 Teoreettinen tukkitilavuus.....	49
4 TULOSTEN TARKASTELU	51
4.1 Mallitusaineistossa saavutetut tarkkuudet	54
4.2 Siirron vaikutus ennusteiden tarkkuuksiin ja menetelmien eroavaisuudet	55
4.3 Ennusteiden harhaisuus siirtojen jälkeen	58
4.4 Syyt alueellisille eroille ennusteiden heikkenemisissä	60
5 JOHTOPÄÄTÖKSET	61
KIRJALLISUUS	62
LIITTEET.....	65

1 JOHDANTO

1.1 Lentolaserkeilaus metsävaratiedon hankinnassa

Ilmasta käsin suoritettava lentolaserkeilaus (Airborne Laser Scanning, ALS) on aktiivinen kaukokartoitusmenetelmä, jolla voidaan tuottaa kohteesta kolmiulotteista (x, y, z) informaatiota: laserkeilain lähettää maanpintaa kohti laserpulsseja, jotka kohteeseen osuessaan heijastuvat kaikuina takaisin keilaimen. Koska keilaimen tarkka kallistuneisuus ja sijainti kullakin ajanhetkellä sekä laserpulslien kulkunopeus (=valonnopeus) tunnetaan, voidaan kunkin kaiun synty-pisteelle laskea tarkka sijainti LiDAR-laitteistolla (Light Detection And Ranging). Yhdistämällä sitten kaikki halutulla alueella sijaitsevat kaiut, voidaan kohteesta muodostaa erittäin yksityis-kohtainen 3D-pistepilvi. Lentolaserkeilauksen yleisiä sovelluskohteita ovat mm. pinnanmuo-tojen, infrastruktuurin, kaupunkialueiden sekä kasvillisuuden, eli siis myös metsien, kartoitta-minen ja mallintaminen. Laserkeilain kiinnitetään yleensä lentokoneeseen, mutta menetel-mää on jonkin verran sovellettu myös kiinnittämällä keilain helikoptereihin ja viime vuosina myös miehittämättömiin lennokkeihin eli drooneihin (Wallace ym. 2016). Lentokone on kui-tenkin ainakin toistaiseksi osoittautunut selvästi parhaimmaksi ja kustannustehokkaimmaksi vaihtoehdoksi, sillä yhdellä kerralla inventoitavat alueet ovat kustannussyistä usein pinta-alal-lisesti erittäin suuria, jopa kymmeniä tuhansia neliökilometrejä.

Lentolaserkeilauksessa on useita säädettäviä yksityiskohtia ja parametreja, jotka vaikuttavat keilauksen lopputulokseen. Pistetiheys, eli se kuinka monta pulssia saadaan keskimäärin rekisteröityä neliömetriä kohden, vaikuttaa suuresti syntyvän aineiston käyttökelpoisuuteen: vuonna 1995 keilaimien pulssitaajuus (Pulse Repetition Frequency, PRF) oli vain 2 kHz (= 2000 pulssia/sekunti), kun nykyisillä keilaimilla voidaan päästä jopa 500 kHz taajuuksiin. Laserkei-lausaineistojen tarkkuus on siis parantunut valtavasti, mikä on mahdollistanut yhä korkeare-soluutisempien 3D-mallien tuottamisen ja niiden piirteiden tunnistuksen, kun ennen hyö-dynnettiin vain pulssien tilastollisia riippuvuussuhteita (Holopainen, 2013).

Pistetiheyteen voidaan vaikuttaa myös lentokorkeudella, lentonopeudella, keilauskulmalla ja lentolinjojen limittäisyydellä. Lentokorkeuden kasvaessa myös pulssin koko kohteeseen osu-essaan kasvaa, ts. syntyvä aineisto ei ole enää niin tiheää ja yksityiskohtaista. Metsiä inventoi-taessa tyypillinen lentokorkeus on 400 – 4000 metriä, jolloin pistetiheys keilaimesta riippuen on yleensä 0,5 – 20 pulssia/m² ja yksittäisen laserkeilan läpimitta kohteeseen osuessaan on 0,1 – 2 m. Tämän vuoksi yhdestä pulssista voidaan saada useita kaikuja, kun pulssin osat hei-

jastuvat eri etäisyyksillä olevista kohteista. Keilauskulma on tyyppillisesti n. 15 astetta lentosuuntaan nähden poikittain ja maastossa linjojen leveys on 100 – 1000 metriä. Viereiset linjat limittyvät toistensa kanssa 10 – 50 prosenttisesti. Laserkeilausparametrien optimointi on useiden tekijöiden summa, jossa eri tekijät vaikuttavat toisiinsa. Esimerkiksi liian suuresta keilauskulmasta aiheutuu linjan laidoilla puiden varjostusta, minkä paikkaaminen taas vaatisi suurempaa lentolinjojen limittäisyyttä. Kapeammalla keilauskulmalla on taas lennettävä korkeammalla, jotta keilautuva linja olisi tarpeeksi leveä, mutta suurempi lentokorkeus puolestaan heikentää yksittäisten pulssien mittaustarkkuutta (Holopainen, 2013). Aineiston laadun kannalta optimaalisinta olisi siis lentää matalalla käyttäen pientä keilauskulmaa ja keskenään reilusti limittäisiä lentolinjoja, mutta tällöin keilauskustannuksetkin olisivat selvästi korkeammat. Yleistäen voikin sanoa, että mitä suurempaa pistetiheyttä tavoitellaan, sitä kalliimpaa on myös aineiston hankinta ja siksi korkean pistetiheyden keilauksia on suoritettu toistaiseksi lähinnä vain tutkimustarkoituksessa. Keilauskustannukset ovat kuitenkin laskeneet tasaisesti laitteistojen ja menetelmien kehittyessä, ja todennäköisesti jatkavat laskuaan edelleen jonkin verran myös lähitulevaisuudessa.

3D-koordinaattien lisäksi useimmilla keilaimilla voidaan nykyään tallentaa myös paluukaikujen voimakkuutta kuvaava intensiteettitieto sekä ns. kaikutyypin. Intensiteetin arvo on riippuvainen keilaimen asetuksista (lähetysvoimakkuus, lähetystaajuus, vastaanottimen asetukset) ja kohteen heijastusominaisuuksista, sekä myös mm. ilmakedästä. Lisäksi kun eri laitevalmistajat voivat mitata ja määritellä intensiteetin eri tavoilla, on intensiteetin kalibrointi haastavaa, mikä edelleen vaikeuttaa intensiteetti- ja vaihe- ja amplitudin johdonmukaista käyttöä puuston tulkintavaiheessa. Pulssien intensiteettitietoa on kuitenkin käytetty onnistuneesti apuna esim. puulajitunnistuksessa (Korpela ym. 2010).

Kaikutyypin puolestaan ilmaisee sen, onko ko. kaiku ainoa, ensimmäinen, keskimäinen vai viimeinen (single, first, intermediate, last) samasta pulssista syntynyt kaiku. Pulssin osuessa latvustoon, voi se joko aiheuttaa vain yhden paluukaikon, tai vaihtoehtoisesti tunkeutua syvemmälle latvustoon ja aina maanpinnalle asti, aiheuttaen toisen/useampiakin paluukaikua. Yleisin tapaus kuitenkin on, että yhdestä pulssista saadaan vain yksi paluukaiku (Holopainen, 2013). Koska tyyppiltään erilaisten kaikujen on havaittu käyttäytyvän eri lailla (ensimmäiset kaiut syntyvät enimmäkseen latvuston yläosassa ja viimeiset kaiut yleensä maanpinnalla), suoritetaan piirteidenlaskenta alkuperäisestä ALS-aineistosta usein erikseen kahteen otteeseen käyttäen toisessa laskennassa vain ensimmäisiä kaikua (single + first) ja toisessa vain viimeisiä

kaikuja (single + last). Usean paluukaiun havaitsemisen ja niiden erottelun mahdollistumisen ansiosta metsikön rakenteesta saadaan siis yhä tarkempaa informaatiota. Keilauksessa käytettävän pulssitaajuuden on huomattu vaikuttavan muodostuvien eri kaikutyypin keskinäisiin suhteellisiin osuuksiin (Næsset, 2008).

Metsien ALS-pohjainen arviointi perustuu siis havaittujen kaikujen ominaisuuksiin ja siihen on kaksi lähestymistapaa: aluepohjainen menetelmä (Area based approach, ABA) sekä yksinpuintulkinta (Individual Tree Detection, ITD). Aluepohjaisessa menetelmässä rekisteröidyistä kaiuista lasketaan suuri määrä niiden korkeus- ja intensiteettiominaisuuksia kuvaavia tunnuksia, kuten mm. keskihajonnat, halutut persentiilit sekä minimi-, keski- ja maksimiarvot. Pistetiheydeksi riittää alle 1 pulssi/m². Koska erilaisten lasertunnusten ominaisuudet ja jakaumat ovat riippuvaisia metsän rakenteesta (valtapituus, pohjapinta-ala, tilajärjestys), voidaan niiden pohjalta rakentaa tilastollisia riippuvuussuhteita ja edelleen ennustaa haluttuja puustotunnuksia. Ennusteiden laatiminen edellyttää toki myös samalta alueelta mitattua tuoretta maastoaineistoa, sillä keilauksissa käytettävät parametrit (keilauskulma, lentokorkeus ym.) vaikuttavat lopputulokseen ja ovat siten keilauskohtaisia. Aluepohjaisessa menetelmässä useiden kymmenien kattavasti puustoiltaan erilaisiin metsiin sijoitettujen ja tarkasti paikannettujen koealojen puustotiedot linkitetään ko. koealalle osuneisiin kaikuihin. Referenssidatan pohjalta voidaan sitten laatia malleja, joilla laserkeilaustunnusten yhtäläisyyksiin perustuen ennustetaan haluttuja tunnuksia lopulta koko inventointialueelle (Næsset 2002, 2004). Tarkastelutasona on nykyisin yleensä 16 m x 16 m pikseleistä koostuva hilaruudukko. Nykyään mm. Metsäkeskuksen operatiivinen metsävaratiedon hankinta pohjautuu Suomessa lähes täysin laserkeilaukseen ja aluepohjaiseen menetelmään, jolla saavutetaan aiemmin käytössä olleeseen kuvioittaiseen arviointiin verrattuna lähes 20 miljoonan euron vuosittaiset säästöt (Hyypä, 2012).

Yksinpuintulkinnassa pääperiaate on sama, mutta koealataso sijaan tarkastelu suoritetaan yksittäisen puun tasolla, mistä johtuen menetelmä lähtökohtaisesti vaatii korkeamman pistetiheyden (> 4 pulssia/m²). Käytetyimmässä ITD:n menetelmässä lähtötietona käytetään laserkeilauspisteparvesta rakennettua ja suodatettua latvuston korkeusmallia (Canopy Height Model, CHM), jonka kukin pikseli on saanut arvonsa lähtökohtaisesti korkeimman ko. pikseliin osuneen kaiun mukaan. Seuraava vaihe on segmentointi, jonka yksinkertaistetusti voisi kuvailla prosessina, jossa CHM:n lokaaleihin maksimeihin luodaan ensin puiden latvapisteet, ja

joista sitten lähdetään aaltomaisesti pikseli kerrallaan etenemään ulospäin, ja algoritmin asetuksista riippuen ko. pikseli joko sisällytetään tai jätetään pois kyseisen puun latvaa kuvaavasta polygonista. Prosessin jälkeen yksittäisten puiden latvat on eroteltu omiksi segmenteikseen, joiden muodot ja pinta-alat tunnetaan tarkasti. Lopullisen segmentin koosta ja muodosta sekä sen sisään jääneiden kaikujen ominaisuuksista voidaan sitten ennustaa puulle läpimitta, pituus ja tilavuus (Hyyppä ym., 2001). Kaikkia puita ei yleensä pystytä varsinkaan nuorissa ja harven-tamattomissa metsissä havaitsemaan, sillä metsän rakenne on latvukseltaan harvoin täysin yksikerroksinen. Myös puuston tiheys ja tilajärjestys vaikuttavat suuresti segmentoinnin onnistumiseen: mitä lähempänä puut ja niiden latvukset ovat toisiaan, sitä heikkolaatuiseksi on segmentoinnin lopputulos. Tässä tutkimuksessa aluepohjaisia laserkeilaustunnuksia laskettiin erikseen sekä yksittäisiin segmentteihin että koko koegan sisään osuneista pulsseista.

1.2 Yleisimpien puustotunnusten ennustaminen ALS-informaatiosta

ALS-datan käyttöä yleisimpien puustotunnusten ennustamisessa on tutkittu paljon. Koska lentolaserkeilauksessa katseluperspektiivi on ylhäältä alas, voidaan metsikön latvusdimensiot havainnoida suoraan ja sen avulla suorittaa tarkkoja laskelmia. Puuston keskipituuden tai yksittäisen puun pituuden ennustaminen onnistuu erityisen hyvin, sillä keilatessa osa pulsseista tunkeutuu puiden välistä aina maanpinnalle asti ja osa pulsseista taas aiheuttaa paluukaiun jo aivan puun latvassa. Tällaisten lähekkäisten kaikujen korkeusero on hyvin lähellä puun pituutta. Pientä aliarvioita aiheutuu usein kuitenkin siitä, että pulssit tunkeutuvat yleensä joitain kymmeniä senttimetrejä ohueen latvustoon, ennen kuin riittävän voimakas paluukaiku syntyy. Lisäksi pituuden aliarviota voi aiheutua siitä, että puun korkeimpaan kohtaan ei ylipäättään osu ainuttakaan pulssia, tai siitä että aluskasvusto on niin tiheä, että se nostaa oletettua maanpintaa todellisuutta korkeammalle. Näiden tekijöiden vaikutusta voidaan pienentää mm. käyttämällä riittävän korkeaan pistetiheyteen kykenevää keilainta, ja riittävän herkkää vastaanotinta (Holopainen, 2013). Keskipituuden ennustamisessa päästään yleensä vähintään n. 1,5 metrin tarkkuuteen, tosin metsän kerroksellisuudella, tiheydellä ja keilauksen pistetiheydellä on jälleen suuri vaikutus lopputulokseen: 15-25 metrisissä tasaikäisissä metsissä pituusennusteilta voidaan odottaa noin 0,5 – 1 metrin tarkkuutta (Næsset, 2002). Tutkimuksessaan Næsset havaitsi myös, että regressioanalyysillä laaditut yksinpuintason pituusmallit ovat tarkempia, kun yksittäisen puun pituuden sijaan ennustetaan koko koegan keskipituutta (Root-mean-square-error eli RMSE 1.49 m vs. 3.15 m) - tosin tutkimusaineiston keskimääräinen pistetiheys

oli alle 2 pulssia/m², mikä johti vain noin 8,5 rekisteröityyn ensimmäiseen paluukaikuun jokaista latvusta kohti. Sittemmin huomattavasti korkeamman pistetiheyden keilausaineistoilla on yksinpuintasolla päästy myös alle puolen metrin tarkkuuteen. Esimerkiksi Vauhkosen ym. (2010) pituusmallin RMSE oli 0,5 m (suhteellinen RMSE 3 %), kun hän ennusti pituutta Random Forest-menetelmällä, aineiston pistetiheyden ollessa 6-8 pulssia/m². Maltamo ym. (2009b) puolestaan saavuttivat pituuden ennustamisessa k-MSN -menetelmällä (k-Most Similar Neighbor) RMSE-arvot 0,38 m/1,95%, kun pistetiheys oli n. 4 pulssia/m². Pituusennusteiden tarkkuuksissa ei ole havaittu olevan suuria eroja eri puulajien välillä.

Puun rinnankorkeusläpimitan ennustaminen ALS-pistepilvestä ei ole enää niin suoraviivaista kuin mitä pituuden ennustaminen on. Käytännössä läpimitta ennustetaan puutasolla puun pituuteen sekä latvuksen dimensioihin perustuen. Pituuden ja läpimitan välinen allometrinen suhde ei kuitenkaan ole niin selvä, kuin mitä riippuvuus läpimitan ja pituuden välillä on, ts. puun pituudesta ei voi päätellä läpimittaa yhtä tarkasti kuin läpimitasta voi päätellä puun pituutta. Tämä koskee erityisesti vanhoja ja pitkiä puita, joilla pituuskasvu on käytännössä päätynyt, mutta joiden runko kuitenkin järeytyy edelleen. Pituudesta johdettuun läpimittaan liittyy näin ollen väistämättä epävarmuutta (Holopainen, 2013). Läpimittaennusteissa on kuitenkin paikoitellen päästy varsin hyviin tarkkuuksiin: Vauhkosen ym. (2010) Random Forest -menetelmällä tuotetun läpimittamallin RMSE-arvot olivat 1,4 cm / 8,2 %, ja edelleen Maltamon ym. (2009b) k-MSN -ennusteet vastaavasti 1,25 cm / 5,16 %, kun selittävinä tekijöinä käytettiin sekä puu- että koealatasen lasertunnuksia ja tarkastelun kohteena oli pelkästään mäntyjä (*Pinus sylvestris*). Yleensäkin läpimitan suhteen hyväksyttävä virhetaso riippuu siitä, paljonko ennuste aiheuttaa virhettä tilavuusennusteeseen, eli suurien puiden kohdalla myös absoluuttinen virhe saa olla suurempi.

Latvusraja on tunnus, joka kertoo, kuinka korkealla puun yhtenäisen latvuksen alin elävä oksa sijaitsee. Siten se on siis yhteydessä mm. puun elinvoimaisuuteen ja edelleen kuviotasolle yleistettynä esimerkiksi harvennustarpeeseen: metsikön pohjapinta-alan kasvaessa myös keskimääräinen latvusraja yleensä nousee. Kotimaisista puulajeista varsinkin männyillä elävän latvuksen raja nousee voimakkaasti puun ikääntyessä, kun taas vastaavasti kuusella latvusraja ei välttämättä juurikaan nouse. Yksittäisen puun latvusrajaan vaikuttaa moni tekijä, ensisijaisesti kuitenkin puun asema ja sijainti muihin puihin nähden. Tiheissä metsissä puidenvälinen kilpailu on kovempaa, minkä johdosta puut panostavat pituuskasvuun, jotta yhteyttämiseen

tarvittavan valon määrä maksimoituisi. Tällöin alaoksat ovat usein selvästi varjostettuja, jolloin niiden elinvoima heikkenee ajan myötä ja ne lopulta kuolevat. Avarassa tilassa kuten esim. puistoissa ja järvien rannoilla kasvaneiden puiden latvusraja onkin usein selvästi alempana kuin vaikkapa vain viisi metriä syvemmällä metsän sisällä kasvavilla puilla. Latvusraja vaihtelee tyypillisesti paljon metsiköiden välillä, mutta vain vähän metsikön sisäisesti, johtuen juurikin mm. erilaisista kasvuolosuhteista ja hoitohistorioista.

Pääsyy siihen, miksi latvusrajaa on haluttu mallintaa ALS-pohjaisesti, on että latvusrajan maanalaista mittaaminen maastossa on hidasta ja työlästä, eikä sen ennustaminen esim. koelakohtaisten tunnusten, kuten pohjapinta-alan, keskipituuden tai kasvupaikkatyyppin, perusteella ole osoittautunut riittävän luotettavaksi lähestymistavaksi. ALS-pistepilvestä periaatteessa saadaankin suoraa informaatiota latvusrajasta, sillä kuvaavathan pisteet metsikön/puun latvusrakennetta. Pulssien käyttäytyminen mm. oksien ja latvuston läpäisyn suhteen voi kuitenkin vaihdella paljonkin, joten esim. pituuteen verrattuna latvusrajan suora määrittäminen ei onnistu lähellekään yhtä luotettavasti. Metsikön keskimääräisen latvusrajan tunteminen olisi kuitenkin hyödyksi monissa eri yhteyksissä: metsänhoidollisten toimenpiteiden kiireellisyyden arvioimisen lisäksi sitä voidaan käyttää myös erityisesti mäntyjen jatkojalostusellista laatua arvioidessa (oksaton tyvitukki, tukkitilavuus) sekä toisaalta myös selittävänä tekijänä mm. oksa- ja neulasbiomassamalleissa (Repola, 2009). Latvusrajan ennustamisessa on tyypillisesti päästy n. 1-2 metrin tarkkuuksiin, ja k-MSN menetelmällä on saavutettu RMSE-arvot 0,79 m / 7,1 % (Maltamo ym., 2009b). Muita käytettyjä lähestymistapoja latvusrajan ALS-pohjaiseksi ennustamiseksi ovat olleet mm. kaikujen korkeusarvojen jakaumien suora analysointi (Solberg ym., 2006) sekä suoraan 3D-pisteparven ominaisuuksien pohjalta suoritettavat laskelmat esim. alpha shape-tekniikalla (Vauhkonen 2010, Maltamo ym. 2010), mutta näillä menetelmillä saavutetut tarkkuudet eivät ole olleet niin hyviä kuin Maltamon (2009b) tutkimuksessa. Poikkeuksena on Bollandssåsin ym. (2011) tutkimus, jossa epälineaarilla sekamallimenetelmällä saavutettiin kuviotasolla 0,54 metrin absoluuttinen RMSE.

Tilavuus on yksi keskeisimmistä puustotunnuksista niin metsätalouden kuin mm. biomassamallien ja siten hiilensidonnankin näkökulmasta, joten sen määrittämistä ALS-aineistoista on tutkittu paljon. Koska tutkimuksissa käytettäviä maastopuita ei yleensä voida kaataa todellisen tilavuuden mittaamista varten, täytyy niille arvioida tilavuus muiden tunnusten avulla. Tilavuuden arviointia varten on kehitetty malleja, joista Suomessa yleisessä käytössä ovat Laasasenahon (1982) kehittämät puulajikohtaiset yhden-kolmen selittäjän tilavuusmallit. Näistä

tarkimpia ovat kolmen selittäjän mallit, joissa otetaan läpimitan ja pituuden lisäksi huomioon myös yläläpimita kuuden metrin korkeudelta. Koska pituutta ei kaikissa tutkimuksissa, eikä edes operatiivisessakaan käytössä, mitata kaikilta puilta (vaan vain koepuilta), joudutaan puuttuvat pituudetkin usein ensin mallintamaan esimerkiksi rinnankorkeusläpimitaan perustuvalla Näslundin käyrällä, ennen kuin Laasasenahon tilavuusmalleja voidaan soveltaa. Näin ollen tutkimuksissa vertailukohtana toimiva laskennallinen tilavuus voi siis yksittäistapauksissa olla kaukanakin todellisesta tilavuudesta.

Tilavuuden tarkastelu voidaan suorittaa joko yksinpuintasolla (l, m^3), tai metsikön kokonaistilavuutena (m^3) tai hehtaarikohtaisena keskitilavuutena (m^3/ha). Aluepohjaisessa menetelmässä koealan puista lasketaan puulajikohtaiset tilavuudet, ja koealalle osuneiden laserkaikujen perusteella luodaan mallit, joilla ennustetaan tilavuudet lopuille alueille. Norjassa ABA-menetelmän pioneiritutkimuksessa Næsset (2002) laati latvuston laserkaikujen korkeusjakaumista regressiomallit, joilla hän kykeni ennustamaan kuviotason keskitilavuutta 11,4 – 14,2 prosentin keskivirheillä. Vastaavasti Suomessa ABA-menetelmän ensimmäisessä kokeilussa Suvannon ym. (2005) tilavuutta estimoineen regressiomallin suhteellinen RMSE oli 9,8 %. Yleisesti ottaen ABA-menetelmällä päästäänkin Suomessa tilavuuden arvioinnissa nykyisin kuviotasolla vähintään noin 10-15 % ja koealatasolla n. 20 % keskivirheeseen: menetelmässä laserpiirteiden apuna käytetään nykyisin myös digitaalisia ilmakuvia, joiden avulla saadaan parannettua mm. puulajikohtaisten tilavuusennusteiden tarkkuutta (Packalén & Maltamo, 2007).

Yksinpuintasolla tilavuutta ennustetaan yleensä ALS-datasta niin ikään suoraan latvuksen leveydestä ja/tai siihen osuneiden pulssien ominaisuuksista. Esimerkiksi Maltamon ym. (2009b) tutkimuksessa k-MSN menetelmällä mäntyjen tilavuuden ennustaminen onnistui 11 % suhteellisella RMSE:llä, mitä yksinpuintasolla voi pitää hyvänä tarkkuutena. Muissa tutkimuksissa tarkkuus on useimmiten jäänyt selvästi heikoimmaksi, esim. Vauhkosen ym. (2010) tutkimuksessa Random Forest -pohjaisen tilavuusennusteen suhteellinen RMSE oli parhaimmillaan 30,1 %. Tosin aineistojen erilaisuus heikentää eri tutkimustulosten suoraa vertailukelpoisuutta: esim. Vauhkosen puumäärältään laajemmassa aineistossa oli mäntyjen lisäksi mukana myös selvästi keskimääräisiltä latvusrakenteiltaan männyistä ja toisistaan poikkeavia kuusia (*Picea abies*) ja lehtipuita, joita ei kuitenkaan tilavuutta tarkasteltaessa eroteltu omiksi ryhmikseen.

Yksittäisen puun tilavuutta on ennustettu myös vaiheittain: Villikan ym. (2007) tutkimuksessa puulle ennustettiin ensin läpimitta käyttämällä selittäjinä ALS-pohjaista pituusestimaattia, latvuksen kokoa sekä latvuksesta syntyneiden kaikujen ominaisuuksia. Saatua läpimittaa käytettiin sitten Laasasenahon (1982) kahden selittäjän tilavuusmallissa. Tarkastelussa oli mukana vain kuusia, ja vaiheittaisen ennusteen tarkkuus osoittautui jopa hieman suoran ALS-ennusteen vastaavaa paremmaksi (RMSE 27,27 % vs. 30,74 %), kun vertailutilavuutena oli Laasasenahon kolmen selittäjän mallilla laskettu tilavuus. Kaiken kaikkiaan ITD-pohjainen tilavuusarviointi ei siis ole Suomessa metsäsuunnittelussa kovinkaan käyttökelpoinen menetelmä, sillä summattaessa yksinpuintulkittuja puutason tilavuuksia kuviotason tilavuudeksi, ei tarkkuus ole riittävällä tasolla mm. havaitsematta jääneistä puista johtuen.

Pelkän kokonaistilavuuden avulla ei kuitenkaan pystytä määrittämään puuston taloudellista arvoa, sillä tavaralajihinnoittelun vallitessa on jokaisella puulajilla (mänty/kuusi/koivu) vielä tavaralajikohtaisetkin (tukki/kuitu/energia) markkinahinnat. Siten arviot puulajikohtaisista tukki-, kuitu- ja myös energiapuukertymistä ovat erittäin oleellisia tunnuksia leimikkosuunnittelussa. Vain muutamissa aluepohjaisen menetelmän tutkimuksissa referenssidatana on käytetty hakkuukoneella katkottuja pölkkyjä, joista tutkimukseen on suoraan saatu mukaan todelliset tukki- ja kuitupuukertymät: Korhosen ym. (2008) tutkimuksessa todellisen tukkipuukertymäennusteen suhteellinen RMSE oli ABA-menetelmällä 18 % ja vastaavasti Peuhkurisen ym. (2008) tutkimuksessa männyllä 32 % ja kuusella n. 65 %. Holopainen ym. (2010) puolestaan ennustivat kuviotason tukkipuutilavuutta kuusivaltaisesta aineistosta erikseen männylle, kuuselle ja koivulle suhteellisten RMSE-arvojen ollessa vastaavasti 79,2 %, 33,6 % ja 78,6 %. Peuhkurisen ym. (2007) tutkimuksessa kuviokohtaista tukkitilavuutta ennustettiin puolestaan neljällä eri ALS-pohjaisella menetelmällä: tulokset vaihtelivat 18,6 % yliarviosta 12,7 % aliarviioon, parhaan menetelmän ennusteen ollessa alle 0,4 % aliarvio. Norjalaisessa tutkimuksessa (Bollandsås ym., 2011) tukkitilavuuden ennustaminen onnistui kuviotasolla 24 % RMSE:llä.

Koska useimmiten tutkittavien puiden todellisia tavaralajikohtaisia tilavuuksia ei ole mitattu, eli käytännössä puita ei ole kaadettu ja mitattu hakkuukoneella, täytyy niille läpimitan ja pituuden (mahdollisesti myös yläläpimitan) avulla sovittaa runkokäyrämalli ja laskea teoreettiset tukki- ja kuitutilavuudet minimiläpimittoihin ja pituusvaatimukseen perustuen. Tukkipuun minimidimensiot vaihtelevat eri toimijoiden ja sahojen välillä, mutta yleinen vaatimus esim. mäntytukille on vähintään 15 cm latvaläpimitta sekä 3,0 metrin pituus. Tällöin puun on siis

oltava vielä n. 3,3 metrin (katkaisukorkeus + minimipituus) korkeudella läpimitaltaan vähintään 15 cm, jotta rungosta saadaan katkottua edes yksi tukkipölkky. Läpimitta- ja pituusvaatimusten lisäksi tukkipuulta edellytetään myös riittävää laatua: esimerkiksi lenkoutta, moniväyryyttä ja mutkia sallitaan tukissa vain hyvin vähän, ja sienivikaa, hyönteisvaurioita ja lahoa puolestaan ei lainkaan. Myös kuolleiden oksien paksuus on rajoitettu yleensä maksimissaan 40 millimetriin.

Toinen vaihtoehto todellisen tukkitilavuuden selvittämiseksi onkin maastomittauksien yhteydessä määrittää rungossa olevat viat sekä mitata niiden sijainti (esim. koro, paksu kuivaoksa) tai tukkisaantoon vaikuttavan osan pituus (esim. liiallinen lenkous x metrin matkalla), mutta myös tällaisia mittauksia toteutetaan vain harvoin, sillä ne ovat hyvin aikaa vieviä ja myös subjektiivisia eli mittaajasta ja hänen käytännön ammattitaidosta ja harjaantuneisuudesta riippuvaisia. Lisäksi pientä epätarkkuutta aiheuttaa se, että tarkka korkeus jossa puunrunko kapenee vaadittua minimiläpimittaa pienemmäksi, jää käytännössä aina runkokäyriin perustuvaksi arvioksi, sillä mittausten yhteydessä määritetään yleensä vain rinnankorkeusläpimitta ($h=1,3$ m) ja yläläpimitta ($h=6,0$ m). Edellä mainittujen luonnossa varsin yleisesti esiintyvien vikojen vaikutusta teoreettiseen tukkitilavuuteen voidaan kuitenkin ottaa huomioon erilaisilla puulajikohtaisilla tukkivähennysmalleilla, jotka huomioivat mm. puun syntyvän sekä kasvupaikkatyyppin (Mehtätalo, 2002). Ilman minkäänlaista vikojen huomioimista teoreettisen ja todellisen tukkitilavuuden välinen korrelaatio voisi esim. rehevien maiden männiköissä olla heikko, mikä edelleen esimerkiksi puuta myyvän metsänomistajan kannalta olisi haitallista, kun tukkikertymät ja siten myös puunmyyntitulot jäisivätkin huomattavasti ennakoarvioita pienemmiksi. Tosin tukkivähennysmallitkin on luotu toimimaan paremmin yksittäisen kuvion sijaan laajemmassa mittakaavassa.

Korhonen ym. (2008) ennustivat tutkimuksessaan todellisen tukkitilavuuden lisäksi myös teoreettista tukkitilavuutta saavuttaen 9,1 % suhteellisen RMSE:n, mikä oli siis lähes kaksinkertainen tarkkuus todelliseen tukkitilavuuteen verrattuna. Yksinpuintasolla teoreettisen tukkitilavuuden ennustamista on tutkittu varsin vähän. Maltamon ym. (2009b) tutkimuksessa ennustettiin tukkipuuosuutta rungon tilavuudesta k-MSN –menetelmällä ja tarkkuus oli hyvä, sillä suhteellinen RMSE oli 8,73 %.

1.3 Laserkeilauspohjaisten puustotunnusmallien siirrettävyys

Olipa kyse sitten aluepohjaisesta menetelmästä tai yksinpuintulkinnasta, vaaditaan laserkeilausaineiston tueksi edelleen varsin suuri määrä maastomittauksia. Mittaukset tulee suorittaa erityisen huolellisesti, ja esimerkiksi aluepohjaisessa menetelmässä koeala on saatava GPS-paikannettua erittäin tarkasti, jotta puustotiedot saadaan linkitettyä oikein koko keilausalueen pisteparvesta leikattuun ko. koealan pisteparveen (Gobakken & Næsset, 2009). Myös yksinpuintulkinnassa maastossa mitatut puustotiedot pitää saada sijainnin avulla linkitettyä juuri oikeisiin puuyksilöihin - tosin puiden sijainnit on mahdollista selvittää latvuston korkeusmallista jo etukäteen, jolloin puita ei tarvitse enää GPS-paikantaa maastossa. Koealojen latvuston korkeusmallien luomiseksi alueen ALS-aineiston pitää kuitenkin olla jo käytettävissä, mikä luonnollisesti edellyttää, että keilaus on suoritettu hyvissä ajoin ennen maastomittauksia. Kaiken kaikkiaan maastotyöt ovat kuitenkin erittäin iso kustannuserä laserkeilausprojekteissa, joten maastomittauksien määrän vähentäminen olisi keino pienentää ALS-projektien kustannuksia. Samalla tuotettavien puustoennusteiden tarkkuus ei kuitenkaan saisi juurikaan laskea, jotta pienemmät kustannukset konkretisoituisivat myös varsinaiseksi hyödyksi.

Mittausten tarve voi tulevaisuudessa vähentyä myös siitä, mikäli laajamittaisessa käytössä olevilla keilaimilla yleisesti saavutettavat pistetiheydet jatkavat kasvamistaan ja toisaalta samalla itse keilausten kustannukset eivät ainakaan nouse. Esimerkiksi puuston latvusrajaa voisi jo ennustaa n. 1-2 metrin tarkkuudella suoraan erittäin tiheäpulssisesta ALS-aineistosta Alpha shape -tekniikalla ilman maastomittauksia (Vauhkonen, 2010). Aineistojen yhä tarkentuessa myös muiden puustotunnusten ennustaminen todennäköisesti helpottuu ja tarkentuu, mikä puolestaan tarkoittaisi, että nykyiseen tarkkuustasoon olisi mahdollista ylittää yhä vähäisemmällä maastotyön määrällä. Lyhyemmällä aikavälillä realistisempi vaihtoehto maastomittauksen vähentämiseksi olisi käyttää mallituksessa apuna jo olemassa olevia, riittävän tarkkoja maastomittausaineistoja. Malleja voitaisiin sitten mahdollisesti kalibroida paikallisiin olosuhteisiin huomattavasti vähäisemmällä maastomittauksilla. Tosin jos menetelmänä on ABA-menetelmän sijaan yksinpuintulkinta, edellyttää se, että referenssidatassa myös puiden tarkat sijainnit on oltava tiedossa, jotta maastotiedot saadaan linkitettyä ALS-aineistoihin. Tällaista kattavaa aineistoa ei ainakaan Suomessa ole saatavilla, ja toisaalta sellaisen toteuttaminen ei mitään todennäköisimmin ainakaan nykyisillä menetelmillä olisi saataviin hyötyihin nähden kannattavaa.

Ongelmallisuus laserkeilauspohjaisten mallien siirrettävyydessä aineistosta toiseen pohjautuu kahteen eri tekijään: keilauksen yksityiskohtiin sekä puuston ominaisuuksiin. Siirrettäessä ongelmien syntyminen on siis käytännössä väistämätöntä, mutta ne voivat toisaalta olla merkittömiäkin, mikäli virhetaso ei nouse liikaa vaatimustasoon nähden. Eri laserkeilaimien suoriutumista vertailtaessa on havaittu, että eri keilaimet voivat tuottaa hyvinkin erilaista aineistoa (Næsset, 2008; Korpela, ym. 2010). Jopa täysin saman keilainmallin eri laiteyksilöiden tuotokset voivat erota toisistaan selvästi, joten eri keilaimilla tuotettujen aineistojen ristiin käyttäminen ilman tappioita tarkkuuden suhteen ei ole aivan yksinkertaista. Lisäksi myös saman keilaimen eri alueilla tuottamat ennusteet voivat erota tarkkuuksiltaan paljonkin (Kotivuori, 2016). Huomattavaa lisävaihtelua tuloksiin aiheuttaa myös kulloinkin käytetyt keilausparametrit - esimerkiksi lentokorkeuden kasvaessa Yun ym. (2004) pituusennusteiden keski- virhe kasvoi 0,76 metristä 1,16 metriin, kun lentokorkeus nostettiin 400 metristä 1500 metriin. Tosin Keränen ym. (2016) puolestaan havaitsivat tutkimuksessaan, että lentokorkeuden nostaminen (2000 m → 3000 m) ei ABA-menetelmällä juurikaan vaikuttaisi saavutettavaan tarkkuuteen.

Eryteisesti keilauksissa tuotetut intensiteettitunnukset voivat poiketa toisistaan huomattavan paljon, sillä intensiteettiarvot ovat keilaimen ja kohteen heijastusominaisuuksien lisäksi riippuvaisia myös ilmakehästä eli toisin sanoen keilaushetken sääolosuhteista (kosteus, pilvet). Keilaimien tuottamia intensiteettejä on kuitenkin mahdollista myös normalisoida, jolloin niiden vertailtavuus paranee (Korpela ym., 2010). Korpela ym. havaitsivat tutkimuksessaan myös, että harmaa- ja tervalepän sekä raidan erottelu muista puista voisi olla mahdollista niiden selvästi korkeampien intensiteettiarvojensa avulla. Näiden laajalehtisten lehtipuiden korkeampien intensiteettiarvojen arveltiin johtuvan niiden tiheämmistä ja syvemmistä latvuksen lehvästöistä. Kuitenkaan esim. haavan, kuusen ja koivun intensiteettien välillä ei ollut vastavia johdonmukaisia eroavaisuuksia.

Puuston ominaisuuksista puolestaan aiheutuu ongelmia siirrettävyyteen, mikäli mallitus- ja validointidata poikkeavat toisistaan selvästi tai mallitusdata ei kata kaikkea validointidatassa esiintyvää vaihtelua, sillä perustuuhan koko aluepohjainen menetelmä maastossa havaittujen puuston ominaisuuksien sekä laserkeilaimella tuotetun pisteparven välisiin tilastollisiin riippuvuussuhteisiin. Mm. puiden koon ja metsikön pohjapinta-alan lisäksi metsiköiden puulajisuhteet voivat tyypillisesti poiketa toisistaan suuresti eri alueiden välillä. Maantieteellinen vaihtelu puustossa näkyy varsinkin pohjois-eteläsuunnassa liikuttaessa: metsikön keskimääräinen

pohjapinta-ala on Etelä-Suomessa selvästi suurempi kuin vaikkapa napapiirillä. Vastaavasti keskimääräinen pohjapinta-ala laskee myös silloin, kun kasvupaikan korkeus merenpinnasta nousee. Puuston rakenteelliset erot vaikuttavat erityisesti ABA-menetelmässä, kun taas yksinpuintasolla keskimääräiset erot eri alueilla kasvavien saman puulajin yksilöiden välillä ovat useimmiten pienempiä.

Aluepohjaisessa menetelmässä esimerkiksi lähes koko Suomen kattavat valtakunnan metsien inventointien (VMI) aineistot olisivat erittäin potentiaalinen vaihtoehto maastotöiden vähentämiseksi. Maltamon ym. (2009a) tutkimuksessa käytettiin VMI-aineistoa mallitusdatana, jonka pohjalta ennustettiin k-MSN –menetelmällä halutut puustotunnukset tutkimusalueen (Kuortane) koealoille. Valitut 526 VMI-koealaa sijaitsivat maantieteellisesti melko lähellä tutkimuksen varsinaisia koealoja ja koko tutkimusalue laserkeilattiin samanaikaisesti, eli mallin siirrosta aiheutunut epätarkkuus liittyi siis pelkästään eroavaisuuksiin puuston ominaisuuksissa VMI- ja tutkimuskoealojen välillä. Saavutetut tulokset olivat rohkaisevia, sillä erillisellä validointiaineistolla saavutetut kuviotason tarkkuudet olivat vain hieman heikompia, kun mallitusdatana käytettiin VMI-koealoja tutkimuksen omista koealoista muodostetun mallitusdatan sijaan. Esimerkiksi VMI-aineistosta ennustetun hehtaarikohtaisen tilavuuden suhteellinen RMSE oli 19,66 %, kun tutkimuksen omalla mallitusdatalla saavutettiin vastaava arvo 18,56 %. VMI-aineistoa käytettiin myös Villikan ym. (2007) tutkimuksessa, kun selvittiin, kuinka VMI-aineistojen pohjalta laadittu valmis yksinpuintason läpimittamalli (Kalliovirta & Tokola, 2005) toimi Kolin aineistossa. Mallilla saatua läpimittaa käytettiin sitten Laasasenahon kahden selittäjän tilavuusmallissa, mutta tilavuusennusteen tarkkuus jäi varsin alhaiseksi, sillä suhteellinen RMSE oli 52,04 %.

Maltamo ym. (2012) tutkivat ALS-pohjaisten mallien kalibrointia yksinpuintasolla. Tutkimuksen samalta alueelta mitatut 70 koealaa jaettiin erillisiksi mallitus- ja validointidatoiksi (56 + 14 koealaa), joten puuston rakenteellinen vaihtelu eri aineistojen kesken ei ollut suurta ja lisäksi myös laserkeilaus oli suoritettu samanaikaisesti. SUR-sekamallien (seemingly unrelated mixed-effects models) kalibrointi suoritettiin käyttämällä BLUP-menetelmää (best linear unbiased predictor), jolla ennusteiden RMSE- ja harha-arvoja saatiin muutamissa tapauksissa parannettua. Esimerkiksi kalibroimalla kuivaoksarajaa (alin kuollut oksa) ennustavaa mallia validointidatan kymmenestä puusta mitatuilla läpimitta-, latvusraja-, kuivaoksaraja- ja pituustie-

doilla, saatiin RMSE pienennettyä n. 2,1 metristä alle 1,4 metriin, mikä oli huomattava parannus. Myös mm. läpimittaennustetta saatiin kalibroinneilla tarkemmaksi, mutta parannus ei ollut kuin noin 0,15 cm.

Mallien siirrettävyyttä ja kalibrointia on kokeiltu myös koko Suomen mittakaavassa (Kotivuori, 2016). Tutkimuksessa käytettiin aluepohjaista menetelmää ja luotiin yleiset mallit valtapituudelle, hehtaarikohtaiselle tilavuudelle sekä biomassalle, käyttäen yhdeksän eri puolella Suomea sijainneen laserkeilausinventoinnin aineistoja. Tätä yleistä mallia sitten verrattiin kunkin aluekohtaisen mallin ennusteisiin, kuitenkin jättäen leave-one-out –menetelmällä kulloinkin vertailukohtana oleva inventointialue pois yleisestä mallista, jolloin referenssidatana siis toimi tutkimuksen 8 muuta aluetta. Aluekohtaiset mallit osoittautuivat kaikilla alueilla kaikkien tunnusten suhteen hieman tarkemmiksi: esimerkiksi tilavuusennusteiden eri alueiden suhteellisen RMSE:n keskiarvo oli inventointialueen ristiin validoinnilla 28,1 %, kun aluekohtaisilla malleilla (joiden mallinnusvaiheessa oli puolestaan jätetty ko. koeala pois; ”jätä-koeala-pois”) vastaava arvo oli 24,0 %. Yleisten mallien tarkkuutta saatiin kuitenkin pääsääntöisesti parannettua aluekohtaisilla kalibroinneilla, esimerkiksi kalibroinnin jälkeen yleisten tilavuusmallien suhteellisen RMSE:n keskiarvo oli enää vain 25,9 %. Kalibrointi suoritettiin valitsemalla kulloinkin kohteena olleesta inventointialueesta ositetulla satunnaisotannalla (jotta saatiin koealoja kaikista tutkittavista kehitysluokista) pieni joukko koealoja, joille ennustettiin BLUP-menetelmällä yhteiset ryhmävaikutukset. Näitä ryhmävaikutuksia käytettiin sitten ennustettaessa halutut tunnuksat koealaotoksen ulkopuolelle jääneille lopuille koealoille. Koealojen satunnaisotoksesta johtuvan vaihtelun vaikutuksen minimoimiseksi tämä kalibrointiprosessi suoritettiin kullakin inventointialueella 10 000 kertaa, ja saaduista RMSE- ja harha-arvoista laskettiin keskiarvot. Kotivuori ym. (2016) havaitsivat tutkimuksessaan, että kalibrointi paransi tilavuus- ja biomassamallien tarkkuutta ja parannus oli selvempi Pohjois- kuin Etelä-Suomessa.

Uttera ym. (2006) puolestaan kokeilivat eri tutkimuksessa (Suvanto ym., 2005) Generalized Least Square –menetelmällä tehtyjen koealatason sekamallien siirrettävyyttä muutamien satojen kilometrien maantieteellisillä etäisyyksillä. Mallitusaineisto ja kohdealueiden ALS-aineistot tuotettiin kutakuinkin samoilla keilausparametreilla. Tutkimuksessa suhteelliset RMSE:t kasvoivat siirtojen myötä seuraavasti (mallitusaineisto → alue₁ / alue₂): keskiläpimitta (9,5 % → 13,4 % / 13,1 %), keskipituus (5,3 % → 10,7 % / 9,1 %), runkoluku (18,1 % → 35,1 % / 40,7 %), pohjapinta-ala (8,3 % → 15,7 % / 22,8 %) ja kokonaistilavuus (9,8 % → 17,8 % / 18,8 %).

Ennusteiden heikkeneminen oli siis varsin selvää, vaikka kohdealueilla tarkastelu suoritettiin koealatasen sijaan kuviotasolla, mikä yleensä on tuottanut tarkempia ennusteita. Heikkenemisestä huolimatta saavutetut tarkkuudet olivat edelleen kuitenkin melko hyviä. Tutkimuksessa kokeiltiin myös Norjassa laadittuja regressiomalleja, joilla niilläkin saavutettiin kohtuullinen tarkkuus metsikkökohtaisten puuston tilavuusennusteiden suhteellisten keskivirheiden ollessa 24-28 % välillä.

Myös Ruotsissa toteutettiin ABA-menetelmän tutkimus vastaavalla paikallisella National Forest Inventory (NFI) –aineistolla (Nilsson ym., 2017). Lineaariset regressiomallit luotiin 11 500 maastokoealan ja useilla eri keilaimilla (pistetiheys 0,5-1,0 pulssia/m²) tuotettujen pisteparvien pohjalta ennustamaan mm. tilavuutta ja pohjapinta-alaa. Koealatasolla RMSE-arvot vaihtelivat tilavuuden suhteen 19,2-25,1 % ja pohjapinta-alan suhteen 20,4-26,7 % välillä. Tutkimuksessa havaittiin myös, että lehtipuuosuuden kasvaessa tilavuuden ennustaminen epätarkentui jonkin verran.

Gopalakrishnan ym. (2015) tutkivat Kaakkois-Yhdysvalloissa, kuinka eri laserkeilaimilla tuotetut aineistot toimivat laajan ja yhtenäisen latvuston korkeusmallin eli CHM:n luomisessa ABA-menetelmällä. Aineisto koostui kaikkiaan 76 eri ALS-projektin tiedoista ja 1800 maastokoealasta. Kaikki aineistot yhdistettiin, ja havaittiin että korrelaatio maastossa mitattujen korkeuksien ja ALS-pisteparvesta johdetun korkeuden 85. persentiilin välillä oli 0,85 eli varsin hyvä. Aineistosta luotiin koealatasen valtapituutta ennustava lineaarinen regressiomalli, jolla saavutettiin 3,0 metrin RMSE. Tutkimuksessa selvitettiin myös, miten monet tekijät, kuten mm. havu/lehtipuuvaltaisuus, metsikön keskipituus, kasvillisuuden heterogeenisyys, koealojen rinteisyys sekä keilauksen pistetiheys ja keilauskulma vaikuttavat latvuston korkeuden ennustamisen tarkkuuteen ALS-datasta. Huomattavin vaikutus oli koealan kasvillisuuden rakenteella: tarkimmat ennusteet saatiin, kun kasvillisuuden rakenteellinen vaihtelu oli pientä, eli koealan puusto oli homogeenistä.

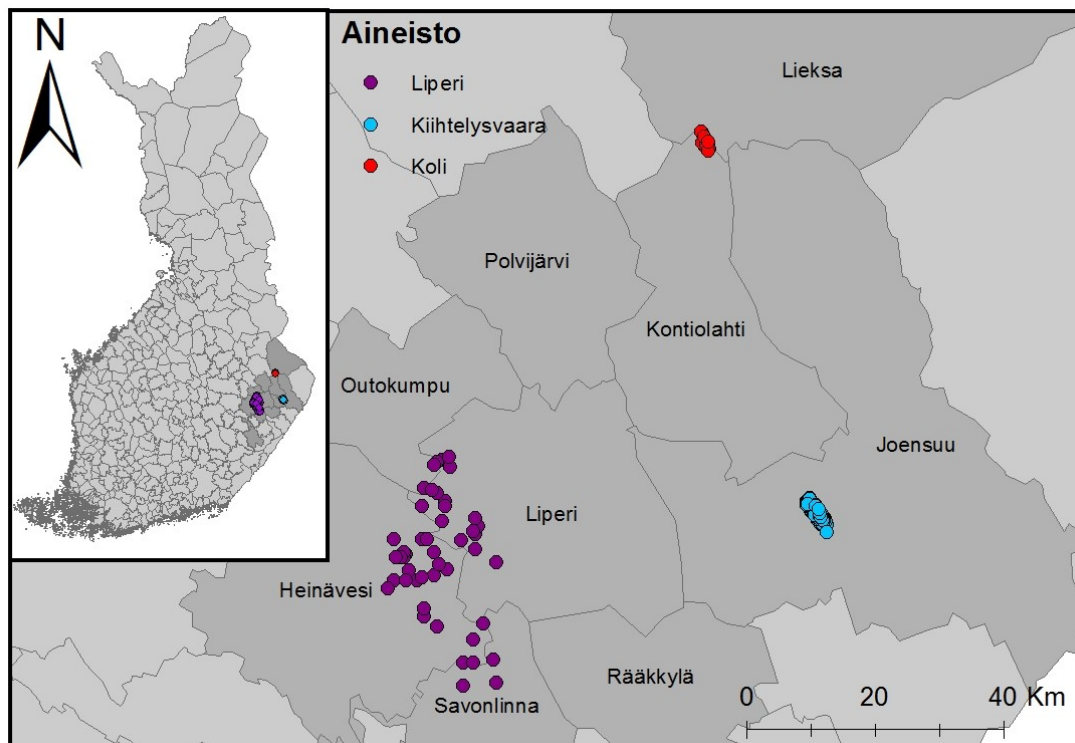
1.4 Tutkimuksen tavoitteet

Tutkimuksen tavoitteena oli selvittää laserkeilausinformaatiopohjaisten yksinpuittaisten puutunnusmallien siirrettävyyttä eli sitä, kuinka paljon puuennusteiden tarkkuus heikkenee, kun mallit siirretään sekä maantieteellisiltä sijainneiltaan että laserkeilauksien yksityiskohdiltaan erilaisiin aineistoihin. Tutkittavat mallit luotiin k-MSN-menetelmällä sekä lineaarisella regressioanalyysillä, ja kiinnostuksen kohteena olleet puustotunnukset olivat puun läpimitta, pituus, latvusraja, rungon kokonaistilavuus sekä rungon tukkitilavuus.

2 AINEISTO JA MENETELMÄT

Tutkimuksessa käytettävä aineisto oli peräisin Itä-Suomesta kolmelta eri alueelta Pohjois-Karjalasta ja osittain Etelä-Savosta, sillä referenssiaineisto oli peräisin Liperin, Outokummun, Heinäveden ja Savonlinnan kuntien alueilta. Jatkossa tästä alueesta puhuttaessa käytetään kuitenkin pelkästään nimitystä Liperi. Referenssiaineistosta johdettujen mallien testausalueita olivat nykyään Joensuun kunnan alueella sijaitseva Kiihtelysvaara sekä Kontiolahten ja Lieksan kuntien rajalla sijaitseva Koli (kuva 1). Suurin etäisyys eri koealojen välillä oli alle 100 km, ja pohjois-eteläsuuntainenkin siirtymä enimmillään 86 kilometriä.

Eri tutkimusalueet poikkesivat toisistaan selvästi siinä, että Kolilla koealat sijaitsivat kansallispuiston vuonna 1991 perustetulla lisäosalla, eli ennen vuonna 2006 suoritettuja mittauksia koealoilla ei ollut suoritettu lainkaan harvennushakkuita viimeiseen 15 vuoteen. Kiihtelysvaaran ja Liperin koealat sen sijaan sijaitsivat metsätalouskäytössä olevissa metsissä, joten vähintäänkin osalla koealoista oli suoritettu harvennushakkuita kyseisen ajanjakson aikana. Harvennushakkuiden seurauksena pystyyn jääneet puut hyödyntävät vapautuneen elintilan kasvattamalla ensin latvustoaan ja siten lisäämällä yhteyttämiskapasiteettiaan, joten tässä tutkimuksessa Kolin koealojen hoitamattomuudella voi olla huomattavakin vaikutus.



Kuva 1. Eri tutkimusalueiden ja niiden koealojen sijoittuminen.

2.1 Maastomittaukset

Referenssiaineiston maastomittaukset suoritettiin Liperin, Outokummun, Heinäveden ja Savonlinnan kuntien alueella kesällä 2017. Alueelta mitattiin tuolloin yhteensä 111 koealaa, mutta tässä tutkimuksessa käytettiin vain niitä koealoja, joilla muiden mittauksien ohella suoritettiin myös ns. mäntyjen laatumittauksia. Laatumittauksissa jokaisesta männystä mitattiin rinnankorkeusläpimitta (1,3 m), yläläpimitta (6 m) ja latvusraja sekä arvioitiin silmävaraisesti laadullisten vikojen sijainnit (esim. lenkous, korot), ja niiden vaikutukset rungon tukkiosuuteen. Näitä mäntyjen laatumittauksia tehtiin vain kehitysluokkien 03- ja 04-koealoilla, joilla kasvoi vähintään viisi rinnankorkeusläpimitaltaan yli 16 senttistä mäntyä. Liperin aineiston lähtötilanteen puustodata onkin siten peräisin 47 eri koealalta.

Mittaukset etenivät siten, että ensin määritettiin koealan perustiedot, kuten kasvupaikkatyyppi, puuston kehitysluokka, maalaji, kuivatustilanne, alikasvoksen määrä jne. Koealan puustomittaukset aloitettiin paikantamalla ensin mukana olleessa, etukäteen luodussa CHM:ssä havaitut puut, jotka numeroitiin ennalta määrätyillä numeroilla. Mikäli CHM:ssä näkyi puu, jota ei todellisuudessa ollut olemassa, poistettiin kyseinen puu maastotietokoneella olleesta koealakohtaisesta tiedostosta – esimerkiksi kaksilatvainen puu näkyy usein CHM:ssä kahtena itsenäisenä puuna, vaikka runkoja tyvellä on todellisuudessa vain yksi. Lisäksi keilausajankohdan ja maastomittauksien välillä puita oli myös saattanut kaatua, jolloin puuttuvat puut poistettiin, tai vaihtoehtoisesti koko koeala hylättiin, mikäli puuttuvia puita oli yli 5 kpl. Näin ollen laserkeilaus- ja maastomittausajankohtien välillä suoritettavat hakkuut johtivat koealan suoraan hylkäämiseen. Yleensä koealoilta löytyi myös vaihteleva määrä puita, joita ei näkynyt valmiissa CHM:ssä (ns. omissiipuut). Omissiipuiksi luettiin kaikki rinnankorkeusläpimitaltaan vähintään 5 cm puut, ja myös ne numeroitiin juoksevasti omilla numeroillaan.

Koealoilta otettiin siis mitattavaksi kaikki läpimitaltaan yli 5 cm puut, ja elektronisille mittasaksille määritettiin ennen puun mittojen ylösottamista myös ko. puun numerokoodi. Kehitysluokan 02-koealoilla puista mitattiin vain rinnankorkeusläpimitta sekä pituus, ja määritettiin puulaji sekä se oliko puu elävä, elävä ja katkennut, kuollut vai kuollut ja katkennut. Kehitysluokiltaan 03- ja 04 –koealoilla em. mittauksien lisäksi määritettiin myös puiden latvusrajat puun yhtenäisen elävän latvuksen alimman oksan tyveen.

Tunnusten mittaamisen lisäksi koealan jokainen omissiopuu vielä paikannettiin erikseen. Paikannus tehtiin ottamalla omissiopuusta sekä suunta että etäisyys vähintään kolmeen ympärillä 2-10 metrin päässä kasvaneeseen CHM:n havaitsemaan puuhun, joiden sijainti oli siis jo ennalta tiedossa ja määritetty latvapisteen x- ja y-koordinaattien mukaan (Korpela ym., 2007).

Kiihtelysvaarassa vuonna 2010 suoritettut maastomittaukset noudattivat hyvin pitkälti samaa periaatetta kuin Liperin alueen mittaukset. Mittaukset poikkesivat kuitenkin mm. siinä että omissiopuiksi luettiin kaikki latvuskartalta tunnistamattomat puut, joiden rinnankorkeusläpimitta oli vähintään 4 cm tai joiden pituus oli vähintään 4 metriä. Lisäksi koealojen koko vaihteli sivuiltaan 20, 25 ja 30 metristen neliönmuotoisten vaihtoehtojen välillä. Kiihtelysvaaran mittauksissa yläläpimitta mitattiin koealan ominaisuuksista riippumatta kaikista rinnankorkeusläpimitaltaan yli 15 senttisistä puista, joten ko. aineiston männyistä yksittäiset yksilöt saattoivat olla peräisin myös esimerkiksi kehitysluokan O2 metsästä. Kiihtelysvaarasta mitattiin yhteensä 79 koealaa, eikä niitä tässä vaiheessa karsittu lainkaan puuston perusteella. Oli siis mahdollista, että kaikilta koealoilta ei edes oltu mitattu ainuttakaan tukkikokoista mäntyä.

Kolin maastomittaukset suoritettiin kesällä 2005 ja alueelta mitattiin yhteensä 29 koealaa. Näistä 15 kuitenkin oli kuusivaltaisia koealoja, joten niitä ei otettu lainkaan mukaan tähän tutkimukseen. Käytössä olleet menetelmät poikkesivat osittain Liperissä ja Kiihtelysvaarassa käytetyistä, mistä johtuen mm. koealat olivat lopulta muodoiltaan vaihtelevan epäsäännöllisiä. Myös puiden sijaintitiedon määrittäminen tapahtui eri lailla. Tämän tutkimuksen kannalta tärkeät puustoa koskevat mittaukset (läpimitta, yläläpimitta, latvusraja) suoritettiin kuitenkin samoilla periaatteilla Liperin ja Kiihtelysvaaran tutkimusalueiden kanssa.

2.2 Laserkeilaus

Kaikki tutkimusalueet on keilattu eri ajankohtina, eri laitteistoilla sekä eri keilausparametreilla (taulukko 1). Kaikki keilaukset suoritettiin kuitenkin kesä- tai heinäkuussa, eli ajankohtana jolloin lehtipuut olivat täydessä lehdessään. Liperin ja Kiihtelysvaaran aineistojen korkeuskoordinaatit olivat valmiiksi normalisoituja, eli yksittäisen kaiun z-koordinaatti kertoi korkeuden maanpinnasta eikä merenpinnasta. Kolin aineiston korkeudet normalisoitiin luomalla viimeisten kaikujen perusteella ensin maanpintaa ja sen muotoja kuvaava eheä kolmioverkosto (Triangulated Irregular Network, TIN), ja laskemalla sitten aineiston jokaisen pisteen korkeus ko. verkostoon nähden.

Taulukko 1. Yksityiskohdat eri tutkimusalueiden laserkeilauksista. Pulssitiheys on alueen koealoilla syntyneiden ensimmäisten kaikujen keskiarvo. Kaikua/latva –keskiarvot laskettiin tutkimuksen lopullisista puista erikseen ensimmäisten/viimeisten kaikujen suhteen.

Alue	Liperi	Kiihtelysvaara	Koli
Keilausajankohta	2.,3.&10.7.2016	26.6.2009	13.7.2005
Keilainmalli	Optech Titan	Optech ALTM Gemini	Optech ALTM 3100
Lentokorkeus (m)	850	600	900
Keilauskulma (°)	40	26	11
Taajuus (kHz)	250	100	100
Kaistojen limittäisyys (%)	55	55	35
Kaistan leveys maassa (m)	650	320	350
Pulssitiheys (pulssia/m ²)	13,2	14,7	5,2
Kaikua/latva (First)	251	283	149
Kaikua/latva (Last)	76	92	76

2.3 Latvuston korkeusmallit


Latvuston korkeusmallin eli CHM:n tekeminen mahdollistaa monia puuston ominaisuudellisia jatkolaskelmia ja -tutkimuksia, kuten esimerkiksi yksinpuintulkinnan suorittamisen. CHM havainnollistaa samalla myös visuaalisesti metsikön ja eritoten latvuston korkeusrakennetta, sillä kukin ruudukon pikseli saa (lähtökohtaisesti) arvonsa siihen osuneiden kaikujen suuriarvoisimman z-koordinaatin eli korkeuden mukaan. Lopulta pikselit voidaan värjätä arvojensa perusteella halutuilla väreillä ja niiden sävyillä. Valmiissa CHM:ssä voi esiintyä myös tyhjiä pikseleitä, sillä ruudukon jokaiseen pikseliin ei välttämättä osu ainuttakaan pulssia. Tyhjät pikselit vaikeuttavat mm. luotettavaa yksinpuintulkintaa, joten niiden määrää tulisi minimoida. Tyhjien pikseleiden ohella myös ns. kuopat (yksi tai useampi pikseli on selvästi ympäröiviään pikseleitä alempana) heikentävät CHM:n käyttökelpoisuutta. Kuoppia syntyy, kun laserpulssit läpäisevät puuston latvustoa ennen ensimmäistä kaikuaan. Kuitenkin sekä tyhjien pikseleiden että kuoppien ilmenemiseen lopullisessa CHM:ssä voi vaikuttaa esimerkiksi luomalla CHM vaiheittain, sen sijaan että kaikille ruuduille annettaisiin vain suora arvo suurimmasta z-koordinaatista.

Liperin tutkimusalueen ALS-pisteparvesta leikattiin kunkin 30x30 m kokoisen laatumitatun koealan pisteparvet viiden metrin lisäpuskureilla, joten leikattujen pisteparvien koko oli 40x40 metriä. Lisäpuskureita käyttämällä myös lähellä koealojen reunoja kasvaneiden puiden latvustot saatiin kokonaisuudessaan mukaan yksinpuintulkintaan. Toinen vaihtoehto olisi ollut hylätä latvukseltaan osittain koealojen ulkopuolella olleet puut, mutta tällöin tutkimuksen malitusaineistosta olisi tullut selvästi pienempi. Keskimäärin näihin 1600 m² neliöihin osui pulsseja n. 21 000 kappaletta, mikä tarkoittaa noin 13,2 pulssia/m². Enimmillään leikatuilla alueilla

pulssimäärä oli n. 26,2 pulssia/m² ja pienimmilläänkin n. 8,8 pulssia/m², joten latvuston korkeusmallien lähtökohtainen pikselikoko asetettiin 0,333 metriin. Tällöin 40x40 metrin alueesta muodostui siis 120 x 120 pikselin ruudukko. Kuopattomat ja tyhjiä pikseleitä sisältämättömät CHM:t muodostettiin kokonaisuudessaan pääosin Khosravipourin ym. (2014) tutkimuksessa esitetyn prosessin mukaisesti. CHM:n luominen aloitettiin erottamalla pisteparvesta kaiut, joiden korkeus eli z-koordinaatti oli alle 0,1 metriä: nämä kaiut heijastuivat siis maasta, ja niiden x- ja y-koordinaateista muodostettiin Delaunayn kolmioinnilla maanpintaa kuvaava TIN ja edelleen maanpinnan digitaalinen korkeusmalli eli DEM (Digital Elevation Model) omaksi tasokseen.

Seuraavaksi kaikkien ensimmäisten kaikujen ympärille lisättiin läpimitaltaan 10 senttimetrinen ”kiekko”: näin yksittäisen kaiun vaikutusalueita saatiin kasvatettua CHM-ruudukossa ja siten laskettua tyhjiä pikseleiden syntyminen todennäköisyyttä. Kaikujen pientä paisuttamista tukee se, että nykyisillä laserkeilaimilla pulssien läpimita kohteeseen osuessaan on todellisuudessaakin lentokorkeudesta riippuen n. 10- 50 cm (Næsset, 2008). Kaikuja paisutettaessa kuitenkin myös ruudukon resoluutio väliaikaisesti kaksinkertaistettiin eli yksi ruutu muuttui neljäksi pienemmäksi, jotta paisuttamisen vaikutus ei olisi liian voimakas jatkotoimenpiteitä ajatellen. Jokainen 0,1667 x 0,1667 metrin ruutu sai siis arvonsa korkeimmasta paisutetusta osumastaan, ja ruudukosta muodostettiin uusi väliaikainen taso.

Seuraavaksi tätä väliaikaista tasoa käytettiin lähtötilanteena, kun muodostettiin yksi kerrallaan osittaiset 0, 2, 5, 10, 15, 20 ja 25 metrin yläpuoliset CHM:t. Nollan metrin CHM luonnollisesti sisälsi kaikki samat kaiut kuin edellisessä vaiheessa tehty väliaikainen tasokin, mutta nyt ruudukon resoluutio oli jälleen 0,333 metriä. Sen lisäksi lopputuloksen rakenteeseen vaikutettiin rajoittamalla laskennassa syntyvien kolmioiden sivun pituus maksimissaan 1,3 metriin. Myös loput osittaiset CHM:t rakennettiin samoilla rajoituksilla, mutta esim. 2 metrin CHM sisälsi siis vain 2 metrin yläpuoliset kaiut ja niin edelleen. Koska eri tasoissa oli käytettävissä eri kaiut ja menetelmän kolmiointia rajoitettiin, poikkesivat osittaiset DEM:t sekä toisistaan että lähtötilanteena käytetystä väliaikaisesta pienempiresoluutioisesta tasosta. Lopulta kaikki edellä mainitut korkeusmallit yhdistettiin yhdeksi korkeusmalliksi valitsemalla kuhunkin 0,333 x 0,333 metrin pikseliin korkein arvo kaikkien edellä luotujen korkeusmallien joukosta (pl. väliaikainen taso). Koska alimmaisena tasona oli maanpintaa kuvaava koko ruudukon kattava taso, ei lopullisessa CHM:ssä esiintynyt yhtään tyhjää pikseliä (kuva 2). Menettelyllä lisäksi esitettiin virheellisten latvusten syntyminen mahdollisten pulssittomien pikseleiden päälle.

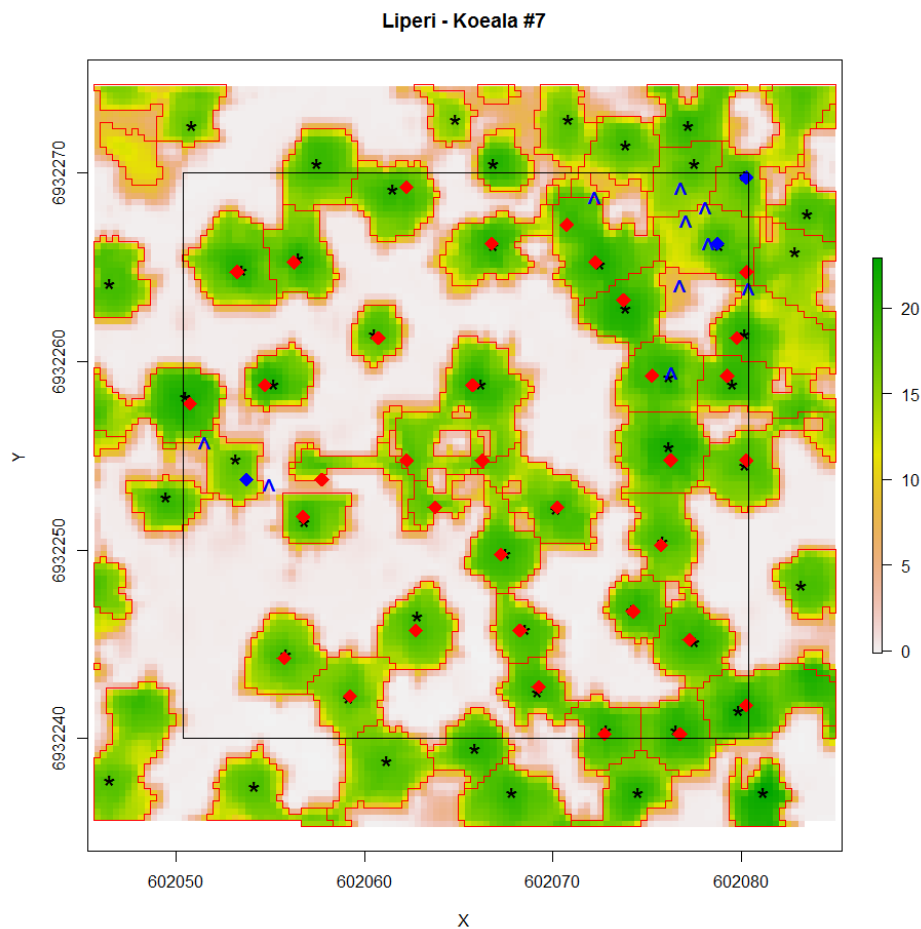


Kuva 2. Esimerkki latvuston korkeusmallista. Värin sävy kuvaa korkeutta maanpinnasta metreinä, x- ja y-akseleilla koordinaatisto. Musta neliö kuvaa koealan rajoja.

Kiihtelysvaaran koaloille muodostettiin latvuston korkeusmallit muuten edellä kuvatulla tavalla, mutta koska koealakoko vaihteli 20 x 20, 25 x 25 ja 30 x 30 metrin vaihtoehtojen välillä, leikattiin sivuiltaan 20 ja 25 metristen koalojen tapauksissa pisteparvesta vastaavasti 30 x 30 ja 35 x 35 metrin ruudukot. Tässä vaiheessa CHM tehtiin varmuuden vuoksi jokaiselle Kiihtelysvaaran koalalle, tietämättä kasvoiko ko. alueella ylipäättään ainuttakaan tukkikokoista mäntyä. Kolin koalat puolestaan olivat muodoltaan ja kooltaankin vaihtelevan epäsäännöllisiä suunnikkaita, joten niiden kanssa käytettiin vieläkin suurempia puskureita, jotta saatiin kaikki maastossa mitatut puut varmasti kokonaisuudessaan mukaan yksinpuintulkintaan. Muilta osin myös Kolin koalojen CHM:t luotiin aiemmin mainittujen yksityiskohtien mukaan. Koealoja oli mallitusaineistossa yhteensä 47, Kiihtelysvaaran aineistossa 79 ja Kolin aineistossa 14 kappaletta. Koealojen määrällä ei sinänsä ollut tässä tutkimuksessa merkitystä, sillä tarkastelu suoritettiin puutasolla. Toki puuston vaihtelu on yleisesti suurempaa koalojen välillä kuin koalojen sisäisesti, joten suurempi koealamäärä tarkoittaisi todennäköisesti myös suurempaa vaihtelua puiden ominaisuuksissa.

2.4 Segmentointi ja yksinpuintulkinta

Koelakohtainen yksinpuintulkinta aloitettiin edellisessä kappaleessa luodun CHM:n pohjalta käyttäen R-ohjelmiston rLiDAR-kirjastoa (Silva, ym. 2017). Aluksi CHM:ää vielä suodatettiin, sillä sen havaittiin ainakin silmämääräisesti hieman parantavan CHM:n laatua. Seuraavaksi puut segmentoitiin automaattisesti, eli koelan puut eroteltiin toisistaan puuston latvuston perusteella (kuva 3). Koska tutkimuksessa oltiin kiinnostuneita vain tukkikokoisista mänyistä, voitiin korkeusrajaksi asettaa 8 metriä – käytetty algoritmi ei siis yrittänytään havaita alle 8 metrin mittaisia puita. Lisäksi segmentointia rajoitettiin määrittämällä latvuksen odotettu maksimisäde 7 metriin ja sallimalla vain pikseleiden, joiden korkeus oli vähintään puolet saman puun suurimmasta korkeudesta, liittäminen puuhun (ns. exclusion-parametri). Mallitusaineistoissa mäntyjen latvusrajan ja pituuden suhde oli noin 2:3, eli esimerkiksi 21 metrisen männyn latvusraja oli keskimäärin 14 metrissä, mikä osaltaan tuki exclusion-parametrin nostamista oletusarvosta 0,3 arvoon 0,5.



Kuva 3. Sama CHM kuin kuvassa 2 segmentoinnin jälkeen. Punaiset polygonit kuvaavat puiden latvuksia, musta tähti latvan korkeinta kohtaa. Kuvaan on lisäksi piirretty maastossa mitattujen puiden sijainnit (punainen ruutu = alkuperäisestä CHM:stä havaittu tukkikokoinen mänty, sininen ruutu = alkuperäisestä CHM:stä havaittu muu puu, sininen väkänä = omissiopuu).

Kuvasta 3 havaittavat pienet erot ruutujen ja mustien tähtien välillä johtuvat siitä, että punaisten ruutujen sijainti oli laskettu eri asetuksilla verrattuna tässä tutkimuksessa suoritettuun segmentointiin. Kyseisten puiden sijainnit olivat siis tiedossa jo ennen maastomittauksia, eikä niitä mittausten yhteydessä enää korjattu millään lailla. Kuva 3 on vain yksi esimerkki tutkimuksessa suoritetuista segmentoinneista, mutta jo siitä voidaan havaita toimenpiteen onnistuneen enimmäkseen hyvin. Ei-manuaalisen segmentoinnin yhteydessä virheitä syntyy lähes väistämättä, varsinkin jos samoilla algoritmin parametreilla segmentoidaan kymmeniä puustoiltaan erilaisia koealoja keskimääräisesti parasta lopputulosta tavoitellen, aivan kuten tässä tutkimuksessa.

Segmentoinnin jälkeen eroteltiin ja laskettiin kuhunkin polygoniin osuneet kaiut. Laskelmat tehtiin kahteen otteeseen kahdella eri kaikutyyppiaineistolla: pelkästään ensimmäisillä kaiuilla, joihin siis sisältyy ainoat ja ensimmäiset kaiut (single & first of many), sekä viimeisillä kaiuilla, eli ainoilla ja viimeisillä kaiuilla (single & last of many). Tässä vaiheessa lopputuloksen optimoimiseksi käyttöön otettiin taas hieman tarkempi, 0,1667 resoluutiolla luotu väliaikainen CHM. Kunkin CHM-latvuspolygonin sisälle osuneista kaiuista laskettiin ko. puulle lasertunnuksia erikseen sekä ensimmäisten että viimeisten kaikujen suhteen. Lasketut tunnuksat kuvasivat polygonin sisään osuneiden kaikujen korkeus- ja intensiteettiarvojen hajontaa. Kaikujen korkeus- ja intensiteettiarvoista laskettiin maksimit, minimi, keskiarvot, mediaanit, moodit, varianssit, keskihajonnat ja variaatiokertoimet. Lisäksi kaikujen korkeus- ja intensiteettijakaumista laskettiin huipukkuus- ja vinousarvot sekä persentiilit suhteellisilla arvoilla 10, 15, ... 80, 90, 95 ja 99. Esimerkiksi korkeuden 95. persentiili kuvaa sitä korkeutta, jonka alapuolella 95% polygoniin osuneista kaiuista sijaitsee.

Tässä vaiheessa laskennassa oli vielä mukana kaikki maastossa mitatut puut. Koska saman polygonin sisään saattoi osua monta maastossa mitattua puuta, ei pelkkä tukkikokoisten mäntyjen suora valikointi ollut tässä vaiheessa riittävä toimenpide. Eri tutkimusalueiden puulistat karsittiinkin vaiheittain siten, että ensin listalta poistettiin omissiipuut - tämä vähensi saman polygonin osumia huomattavasti, sillä ylivoimaisesti suurin osa omissiipuista sijaitsi maastossa suurempien puiden alla (esim. alikasvoskuuset). Segmentoinnissa kaikkia lähekkäin kasvavia suuriakaan puita ei kuitenkaan aina onnistuta erottamaan toisistaan, joten saman polygonin osumia saattoi edelleen ilmetä. Kuvan 3 keskialue on yksi esimerkki tällaisesta tapauksesta: puuston kovin rikkonainen, mutta silti toisissaan kiinni oleva latvusto on segmentoitu virheellisesti eikä kaikki punaiset ruudut edes ole yksittäistä puuta kuvaavassa polygonissa

(musta tähti puuttuu). Aineistoista siis poistettiin vielä varmuuden vuoksi kaikki ne puut, jotka jakoivat saman polygonin toisen puun kanssa. Jäljelle jääneistä puista tutkimuksen lopulliseksi aineistoksi valittiin vain ne männyt, joiden rinnankorkeusläpimitta oli vähintään 16 cm ja joiden yläläpimitta ja latvusraja olivat tiedossa.

Lopullisessa aineistossa oli yhteensä 1782 tukkikokoista mäntyä, joista 1051 kpl oli peräisin Liperin, 414 kpl Kiihtelysvaaran ja 317 kpl Kolin aineistoista (taulukko 2). Liperin alueella puut olivat keskimäärin suurempia ja Kiihtelysvaarassa pienempiä. Taulukosta 2 huomataan myös, että eri keilaimilla saadut maksimi- ja keskimääräiset intensiteetit poikkesivat toisistaan huomattavasti, eli ne eivät olleet käyttökelpoisia myöhemmissä mallinuksissa, kuten ei näin ollen myöskään mm. intensiteetin persentiilit. Eri keilaimien tuottamia intensiteettejä ei lainkaan yritetty normalisoida keskenään yhdenmukaisiksi tässä tutkimuksessa. Luoduista intensiteetitunnuksista vain intensiteettijakauman huipukkuutta ja vinoutta sekä intensiteetin variaatiokerrointa kuvaavat suhteelliset tunnuksot olivat eri alueilla keskiarvoiltaan niin lähellä toisiinsa, että niiden käyttöä myöhemmissä mallinuksissa ei estetty.

Taulukko 2. Tutkimukseen mukaan otettujen mäntyjen maastossa mitattujen/niihin pohjautuvien tunnusten keskiarvoja. Alaosassa lisäksi muutamien intensiteetitunnusten keskiarvoja: IMAX = Intensiteetin maksimi, IMEAN = intensiteetin keskiarvo, IKUR = intensiteettijakauman huipukkuus, ISKE = intensiteettijakauman vinous, ICV = intensiteettien variaatiokerroin. Merkintä _f tarkoittaa, että tunnus on laskettu vain ensimmäisistä kaiuista.

Alue	Liperi	Kiihtelysvaara	Koli	Kaikki
Puumäärä (kpl)	1051	414	317	1782
Läpimitta (cm)	24,8	23,1	24,6	24,3
Yläläpimitta (cm)	19,7	16,9	19,3	19,0
Pituus (m)	21,2	19,5	19,9	20,6
Latvusraja (m)	13,3	11,0	11,2	12,4
Tilavuus (l)	507,1	375,3	472,4	470,3
Tukkitilavuus (l)	418,7	276,6	386,4	380,0
IMAX_f	18,5	113,2	50,0	46,1
IMEAN_f	7,6	54,5	27,4	22,0
IKUR_f	2,33	2,35	2,43	2,35
ISKE_f	0,22	-0,14	-0,31	0,04
ICV_f	57,2	49,9	43,8	53,1

2.5 Koealaston lasertunnukset

Jokaiselle koealalle laskettiin lisäksi koealaston lasertunnukset kaikista koealalle osuneista kaiuista. Laskentaa varten eri tutkimusalueiden pisteparvista leikattiin kukin koeala uudestaan ilman puskurivyöhykkeitä, ja lopulta koealaston tunnukset linkitettiin kuhunkin koealalla kasvaneeseen puuhun. Lasketut koealaston tunnukset olivat hyvin pitkälti samoja kuin puutasollakin, eli ne kuvasivat kaikujen korkeus- ja intensiteettiarvojen hajontaa ja jakaumaa. Mitä takaava vain muuttui puutason polygonista koko koealan kattavaksi. Nämä koealaston lasertunnukset otettiin muuttujavaihtoehdoiksi mukaan mallinnuksiin puutason lasertunnusten rinnalle.

2.6 Tilavuuden laskenta

Tutkimuksen männyille laskettiin tilavuudet Laasasenahon (1982) kolmen selittäjän mallilla (kaava 1). Lisäksi kullekin puulle laskettiin teoreettiset tukki- ja kuituosan tilavuudet integroimalla tunnettujen rinnankorkeus- ja yläläpimitan kautta kulkevan runkokäyrän muodostamaa pyörähdyskappaletta tukkipuun 15 cm ja kuitupuun 7 cm minimiläpimitaan asti käyttäen Laasasenahon (1982) runkokäyrämallia. Hukkapuun tilavuus saatiin lopulta vähentämällä puun kokonaistilavuudesta tavaralajikohtaiset tilavuudet. Tässä tutkimuksessa kuitu- ja hukkapuun tilavuuksia ei kuitenkaan hyödynnetty mitenkään.

$$V_{M\ddot{a}nty} = 0,268621 d^2 - 0,014543 d^2 h - 0,0000478628 d^3 h + 0,000334101 d^2 h^2 + 0,0973148 (d^2 + d d_6 + d_6^2) + 0,0440716 d_6^2 (h - 6) \quad (1)$$

jossa

$V_{M\ddot{a}nty}$ = männyn tilavuus (l)

d = läpimitta 1,3 metrin korkeudelta (cm)

d_6 = läpimitta 6 metrin korkeudelta (cm)

h = puun pituus (m)

2.7 k-Most Similar Neighbour –mallit (k-MSN)

Epäparametrisessa lähimmän naapurin (NN) menetelmässä kohdeaineistolle ennustetaan halutut arvot referenssidatasta perustuen selittävien ja selitettävien muuttujien yhtäläisyyksiin referenssi- ja kohdedatojen välillä. Kullekin kohdeaineiston havainnolle etsitään referenssida-

tasta selittävien tekijöiden arvojen suhteen k lähintä naapuria, ja näiden naapureiden selitettävien tekijöiden arvoista ennustetaan arvot myös kohdeaineiston havainnoille. Kun $k > 1$, painotetaan mallinnuksessa naapureita siten, että kaikkein lähin saa suhteellisesti suurimman ja k . lähin naapuri suhteellisesti pienimmän painoarvon.

k -MSN on yksi NN-menetelmän etäisyysfunktiovaihtoehdoista. Siinä selittävien tekijöiden suhteen samankaltaisimpien naapureiden valinnassa käytetään kanonisella korrelaatioanalyysillä luotua painoarvomatriisia, joka maksimoi selittävien ja selitettävien tekijöiden välistä korrelaatiota (kts. tarkemmin liite 1). Tässä tutkimuksessa k -MSN-malleihin valittiin selitettäväksi muuttujiksi puun rinnankorkeuslähimitta, pituus, latvusraja, kokonaistilavuus sekä teoreettinen tukkitilavuus. Selittävinä muuttujina käytettiin ainoastaan kokeilemalla valittuja laserkeilauspisteparvista johdettuja sekä puu- että koealatasen tunnuksia ja referenssidatana toimi Liperin alueelta mitatut puut. Kaikki tunnuksat ennustettiin samanaikaisesti eli yksittäiselle puulle ennustettiin kaikki tunnuksat samoista referenssipuista, jolloin tunnusten keskinäiset suhteet olivat loogisia. Erillisillä malleilla ennustettaessa näin ei välttämättä olisi käynyt, vaan esimerkiksi latvusrajan ennuste olisi voinut olla korkeammalla kuin puun pituus. Naapureiden lukumäärä k oli kaikissa tapauksissa 5.

2.8 Lineaariset regressiomallit

Myös lineaarisessa regressiomallinnuksessa (LR) selittävinä muuttujina käytettiin pelkästään laserkeilaustunnuksia. LR-mallit luotiin Liperin aineistosta erikseen lähimitalle, pituudelle, latvusrajalle, kokonaistilavuudelle sekä tukkitilavuudelle. Erilaisia potentiaalisia lasertunnuksia oli mallinnuksen alussa reilusti yli sata, joten ensiksi selittäjävaihtoehdoista karsittiin heikoimmat pois käyttämällä kaikkia vaihtoehtoja selittävinä tekijöinä, ja poistamalla vaiheittain merkitsevyydeltään heikoimmat eli p -arvoltaan suurimmat vaihtoehdot (ns. poistava valinta). Ensiksi poistettiin selittäjät, joiden p -arvo oli suurempi kuin 0,9, sitten ne joilla $p > 0,8$ ja niin edelleen, kunnes kaikkien selittäjävaihtoehtojen p -arvo oli alle 0,001. Lopulta näiden muutama kymmenen potentiaalisimman selittäjäkandidaatin joukosta valittiin kokeilemalla paras maksimissaan kolmen eri tunnuksen yhdistelmä mallintamaan kyseessä olevaa tunnusta.

Käytettävien tunnusten keskenäinen korrelaatio testattiin vielä ristiin VIF-testillä (Variance Inflation Factor), ja mikäli testin tulos oli yli 5, vaihdettiin heikompi/toinen tunnuksista sellaiseen, joka ei enää korreloinut vahvasti testin toisen osapuolen kanssa. Näin voitiin varmistua

siitä, että tunnusten välinen korrelaatio ei enää aiheuttanut ongelmia regressiomallien tarkkuuteen eli tuloksissa ei ilmentynyt multikolinearisuutta.

2.9 Tarkkuuden arviointi

Mallien tarkkuuden pääarviointikeinona käytettiin absoluuttista RMSE:tä (kaava 2), josta johdettiin edelleen myös suhteelliset RMSE-arvot (%-RMSE) kullekin tunnukselle (kaava 3). Myös mallien tuottamaa absoluuttista harhaa (BIAS; kaava 4), sekä siitä edelleen johdettua suhteellista harhaa (%-HARHA; kaava 5) käytettiin tarkkuuden arvioinnissa.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(X_i - Y_i)^2}{n}} \quad (2)$$

$$\% - RMSE = \frac{100}{\bar{x}} * \sqrt{\sum_{i=1}^n \frac{(X_i - Y_i)^2}{n}} \quad (3)$$

joissa

n = mäntyjen määrä tutkimusalueella

X_i = Ennustettu arvo

Y_i = Mitattu arvo

\bar{x} = tunnuksen mitattu keskiarvo tutkimusalueella

$$HARHA = \sum_{i=1}^n \frac{(X_i - Y_i)}{n} \quad (4)$$

$$\% - HARHA = \frac{100}{\bar{x}} * \left(\sum_{i=1}^n \frac{(X_i - Y_i)}{n} \right) \quad (5)$$

joissa

n = mäntyjen määrä tutkimusalueella

X_i = Ennustettu arvo

Y_i = Mitattu arvo

\bar{x} = tunnuksen keskiarvo tutkimusalueella

Lisäksi lineaaristen regressiomallien onnistumisen arvioinnissa käytettiin apuna myös jäännös-kuvaajia (esim. kuva 4, s.33), joissa x-akselilla on ennustettu arvo ja y-akselilla mallin tuottamat jäännökset eli poikkeamat havaituista arvoista (havainto – ennuste). Jäännöskuvaajasta mallissa mahdollisesti ilmenevät heteroskedastisuus (=jäännösten varianssi vaihtelee systemaattisesti, kun ennustettu arvo muuttuu) ja/tai epälinearisuus on helppo havaita. Jommankumman em. seikan ilmeneminen jäännöskuvaajasta taas kertoo siitä, että malli tarvitsee muunnoksia (esim. logaritmi- tai neliöjuuri) tuottaakseen harhattomampia ennusteita.

3 TULOKSET

Tässä osiossa esitellään tutkimuksen tunnuskohtaiset (läpimitta, pituus, latvusraja, kokonaistilavuus, teoreettinen tukkitilavuus) tulokset RMSE- ja harha-arvojen sekä jäännös- ja hajontakuvaajien avulla: Kiihtelysvaaran ja Kolin tuloksia verrataan Liperin vastaaviin. Ensiksi käsitellään k-MSN-mallinnus (luvut 3.1.1-5), sitten lineaariset regressiomallit (luvut 3.2.1-5).

3.1 k-MSN-menetelmä

Menetelmää kokeiltiin useilla eri selittäjäyhdistelmillä. Tavoitteena oli muodostaa Liperin datasta läpimittaa, pituutta, latvusrajaa, kokonaistilavuutta sekä teoreettista tukkitilavuutta ennustava k-MSN-malli, jonka tuottamat RMSE-arvot kaikkien eri tunnusten suhteen olisivat yhtäaikaisesti mahdollisimman pieniä. Alun perin tavoitteena oli sisällyttää malliin 10 eri laserkeilausdatasta johdettua selittäjää, joiden valinta suoritettaisiin kokeilemalla. Alhaisimpiin RMSE-arvoihin päästiinkin yhdistelmällä, jossa oli 5 korkeus- ja 5 intensiteettitunnusta (liite 2), mutta kuten todettua, muut kuin suhteelliset intensiteettitunnukset eivät sovellu siirrettäväksi, joten ko. intensiteettitunnuksia ei hyväksytty mukaan malliin.

Selittäjävalintaprosessia jatkettaessa kävi ilmi, että nämä viisi jäljelle jäänyttä korkeustunnusta toimivatkin mallissa varsin hyvin – selittäjämäärän kasvattaminen yhteensä kymmeneen korkeustunnukseen ei käytännössä parantanut RMSE-arvoja yhtään, vaan useimmissa tapauksissa jopa huononsi niitä. Vielä kuitenkin huomattiin, että lisäämällä selittäjälistaan kaksi suhteellista intensiteettitunnusta RMSE-arvot pienenevät. Tässä tutkimuksessa käsiteltäväksi otettiin lopulta nämä kaksi k-MSN-mallia: versio 1, jossa selittäjinä oli viisi korkeustunnusta ja versio 2, joissa selittäjinä oli lisäksi kaksi suhteellista intensiteettitunnusta (taulukko 3). Versioiden kuvaajat eivät käytännössä juurikaan poikenneet toisistaan, joten tulosten yhteydessä näytetään vain 2. version tuottamat kuvaajat. 1. version kuvaajat löytyvät liiteosasta (liite 3).

Taulukko 3. k-MSN-mallissa käytetyt lasertunnukset. Tunnuksen lopussa oleva kirjain ilmaisee, millä tasolla ja mistä kaikutyyppistä tunnus on laskettu: f = puutason ensimmäiset kaiut, l = puutason viimeiset kaiut, p = koealatasen kaikki kaiut.

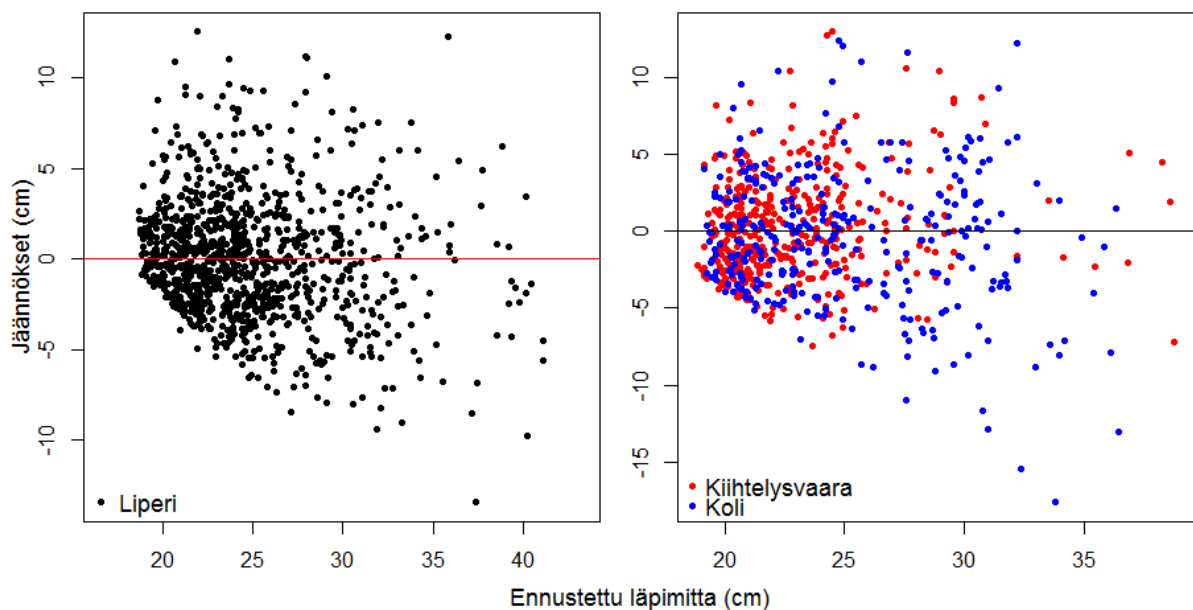
Tunnus	Selite
HMAX_f	Korkeuden maksimiarvo
H55TH_l	Korkeuden 55. persentiili
H90TH_f	Korkeuden 90. persentiili
HSD_p	Korkeuksien keskihajonta
H15TH_p	Korkeuden 15. persentiili
ICV_f	Intensiteettien variaatiokerroin (vain 2. versiossa)
ISKE_p	Intensiteettijakauman vinous (vain 2. versiossa)

3.1.1 Lämpimitta

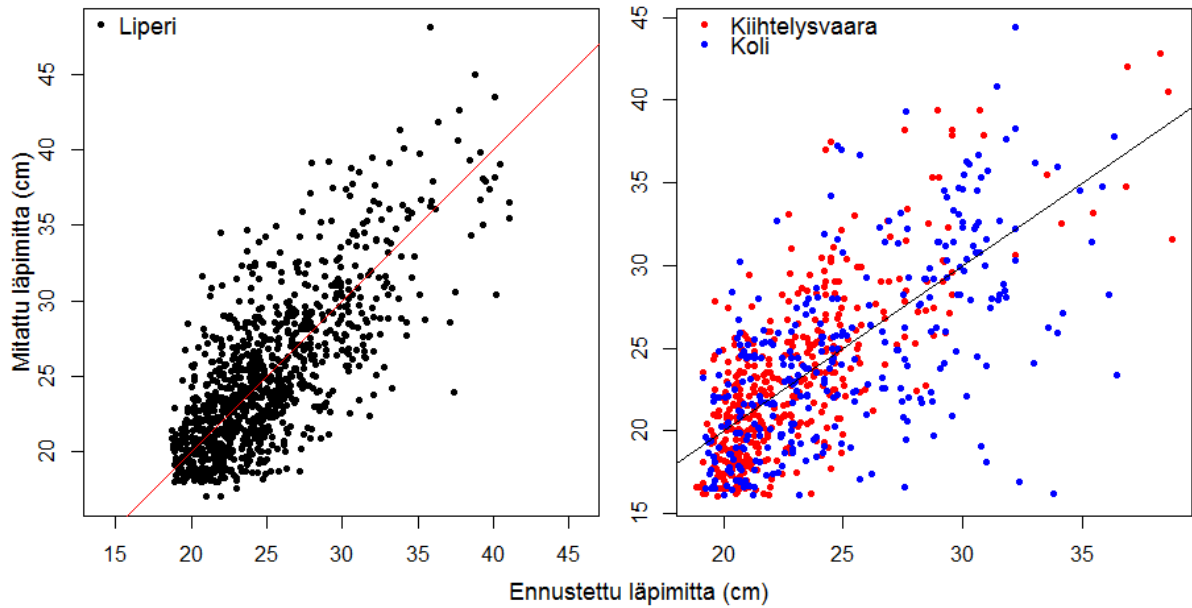
k-MSN -menetelmällä puiden läpimitan ennustaminen onnistui mallitusdatassa 3.3 cm tarkkuudella – suhteellinen RMSE oli 13,5 % (taulukko 4). Kaksi suhteellista intensiteettitunnusta sisältänyt 2. versio oli kaikilla alueilla hieman tarkempi. Kiihtelysvaarassa absoluuttinen RMSE ei juurikaan heikentynyt, ja suhteellinenkin RMSE kasvoi 1. versiossa vain n. 1,3 prosenttiyksikköä ja 2. versiossa vain noin prosenttiyksikön. 1. version harhaisuus kasvoi siirtojen myötä, siten että menetelmä tuotti pientä järjestelmällistä aliarviota molemmilla alueilla. Kolin alueella erot RMSE-arvoissa olivat selvempiä. Absoluuttinen RMSE kasvoi molemmissa versioissa yli senttimetrillä, mikä suhteellisena RMSE:nä osoittautui lähes 5 prosenttiyksikköä Liperin aineistoa huonommaksi. Kiihtelysvaarasta poiketen k-MSN-menetelmän 2. versio tuotti Kolin alueella hieman yliarviota.

Taulukko 4. k-MSN-mallien tuottamat RMSE- sekä harha-arvot läpimitan suhteen eri alueilla.

		Liperi	Kiihtelysvaara	Koli
Versio 1	RMSE (cm)	3,4	3,5	4,6
	%-RMSE	13,7	15,0	18,5
	HARHA (cm)	-0,0	-0,4	-0,4
	%-HARHA	-0,2	-1,6	-1,7
Versio 2	RMSE (cm)	3,3	3,3	4,4
	%-RMSE	13,5	14,5	18,0
	HARHA (cm)	0,0	-0,2	0,5
	%-HARHA	0,1	-0,7	1,9



Kuva 4. k-MSN-mallin tuottamat jäännöskuvaajat läpimitan suhteen.



Kuva 5. k-MSN-mallin tuottamat hajontakuvaajat läpimitan suhteen.

Mallin tarkkuus heikentyi hieman läpimitan kasvaessa (kuvat 4 & 5). Myös näistä kuvaajista näkyy, että malli oli taipuvainen tuottamaan Kiihtelysvaarassa aliarvioita ja Kolilla yliarvioita.


3.1.2 Pituus

Pituuden ennustamisessa pelkkiä korkeustunnuksia sisältänyt versio 1 oli mallitusdatassa hieman tarkempi: absoluuttinen RMSE oli 0,67 metriä ja suhteellinen RMSE 3.16 % (taulukko 5). 1. versio oli tarkempi myös Kiihtelysvaarassa, jossa %-RMSE kasvoi Liperiin nähden 2,83 prosenttiyksikköä. Kolin alueella puolestaan 2. versio oli hieman tarkempi, mutta suhteellinen RMSE kasvoi 3,56 prosenttiyksikköä eli tarkkuus oli jo yli kaksinkertaisesti heikompi Liperiin verrattuna.


Taulukko 5. k-MSN-mallien tuottamat RMSE- ja harha-arvot pituuden suhteen eri alueilla.

		Liperi	Kiihtelysvaara	Koli
Versio 1	RMSE (m)	0,67	1,17	1,39
	%-RMSE	3,16	5,99	6,97
	HARHA (m)	0,00	-0,54	0,54
	%-HARHA	-0,01	-2,76	2,72
Versio 2	RMSE (m)	0,68	1,31	1,35
	%-RMSE	3,23	6,73	6,79
	HARHA (m)	-0,02	-0,61	0,47
	%-HARHA	-0,09	-3,10	2,33

k-MSN-malli osoittautui pituuden ennustamisessa varsin toimivaksi, sillä varianssi ei käytännössä muuttunut ennustetun pituuden kasvaessa (kuvat 6 & 7). Myös pituuden suhteen menetelmä tuotti Kiihtelysvaarassa järjestelmällisesti pieniä aliarvioita ja Kolilla vastaavia yliarvioita. Tosin varsinkin Kolin alueella on muutamia selviä poikkeavia havaintoja eli outlierieitä, joilla oli todennäköisesti suuri vaikutus harhaan. Kyseisille havainnoille ei myöskään oltu merkitty mitään poikkeavia huomioita alkuperäiseen Kolin mittausdataan, eli virheet eivät olleet seurausta esim. katkenneista tai taipuneista rungoista.



Kuva 6. k-MSN-mallin tuottamat jäännöskuvaajat pituuden suhteen.



Kuva 7. k-MSN-mallin tuottamat hajontakuvat pituuden suhteen.


3.1.3 Latvusraja

Latvusrajan ennustamisessa 2. versio oli jälleen Liperissä tarkempi, RMSE-arvojen ollessa 1,72 metriä ja 13 % (taulukko 6). Suhteellinen RMSE heikentyi 2,36 prosenttiyksikköä siirrettäessä malli Kiihtelysvaaraan, jossa pelkkiä korkeustunnuksia sisältänyt versio 1 oli hieman tarkempi. Kolin siirrettäessä tarkkuus heikkeni 2. versiossa yli 6 prosenttiyksikköä. Huomionarvoista on myös se, että pelkkiä korkeustunnuksia sisältäneessä 1. versiossa ero Liperin ja Kolin suhteellisten RMSE-arvojen välillä oli jo selvästi suurempi, lähes 10 %.


Taulukko 6. k-MSN-mallien tuottamat RMSE- ja harha-arvot latvusrajan suhteen.

		Liperi	Kiihtelysvaara	Koli
Versio 1	RMSE (m)	1,77	1,73	2,59
	%-RMSE	13,33	15,69	23,09
	HARHA (m)	-0,01	0,12	1,28
	%-HARHA	-0,05	1,09	11,42
Versio 2	RMSE (m)	1,72	1,75	2,16
	%-RMSE	13,00	15,84	19,24
	HARHA (m)	-0,04	-0,50	0,45
	%-HARHA	-0,28	-4,53	4,01

Myös latvusrajaennusteiden jäännökset asettuivat menetelmällä varsin tasaisesti nollan molemmin puolin koko x-akselin matkalla (kuva 8). Kiihtelysvaaran ja Kolin alueilla tarkkuus näyttäisi sen sijaan hieman heikentyvän ennustetun latvusrajan noustessa. Tässäkin tapauksessa malli oli taipuvainen tuottamaan Kiihtelysvaarassa aliarvioita ja Kolin yliarvioita, tosin jälleen Kolin aineistossa on muutamia erittäin räikeitä outliereitä (kuva 9).



Kuva 8. k-MSN-mallin tuottamat jäännöskuvaajat latvusrajan suhteen.



Kuva 9. k-MSN-mallin tuottamat hajontakuvaajat latvusrajan suhteen.

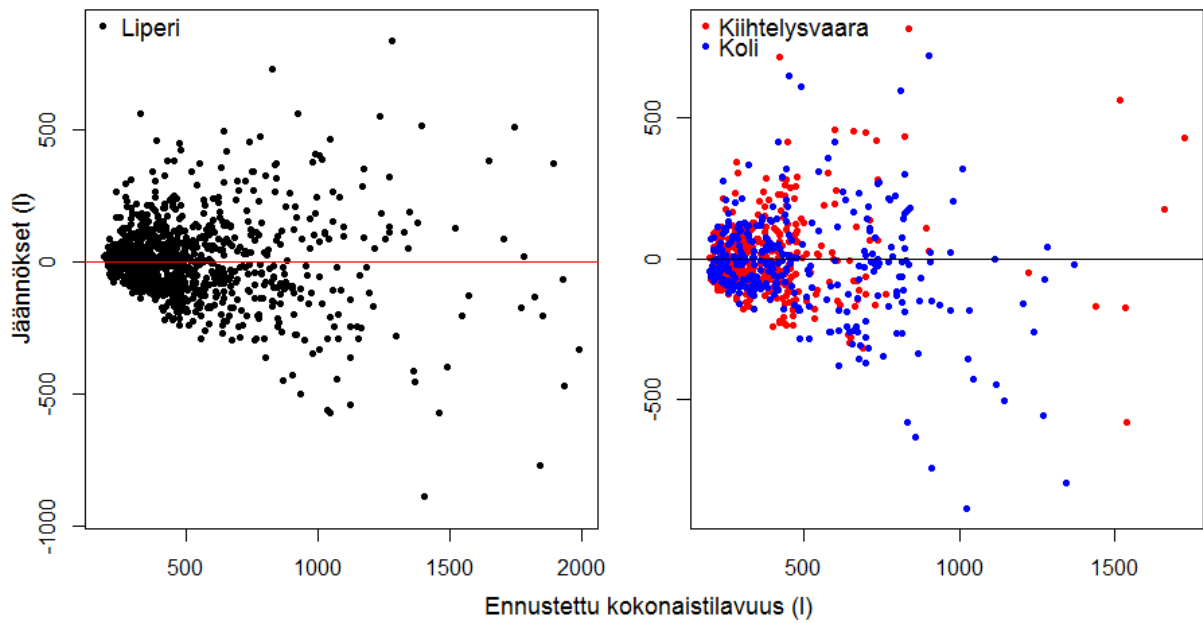
3.1.4 Kokonaistilavuus

Kokonaistilavuuden ennustamisessa 2. versio oli Liperin datassa hieman tarkempi (taulukko 7). Suhteellinen RMSE oli hieman alle 30 %. Kiihtelysvaarassa mallin absoluuttinen RMSE oli jopa selvästi pienempi, mutta se johtuu siitä, että Kiihtelysvaarassa mäännetyt olivat keskimäärin pienempiä kuin Liperissä (taulukko 2, s. 28) – suhteellinen RMSE olikin lähes 7 prosenttiyksikköä Liperin vastaavaa suurempi. Kiihtelysvaarassa 1. versio oli hieman tarkempi, Koliilla puolestaan 2. versio. Koliilla suhteellinen RMSE oli jo yli 40 % ja suhteellinen harhakin oli lähes 5,5 %.


Taulukko 7. k-MSN-mallien tuottamat RMSE- ja harha-arvot kokonaistilavuuden suhteen eri tutkimusalueilla.

		Liperi	Kiihtelysvaara	Koli
Versio 1	RMSE (I)	155,6	137,5	193,6
	%-RMSE	30,7	36,6	41,0
	HARHA (I)	-1,8	-0,2	-3,8
	%-HARHA	-0,3	-0,1	-0,8
Versio 2	RMSE (I)	151,2	137,7	189,9
	%-RMSE	29,8	36,7	40,2
	HARHA (I)	2,4	2,2	25,8
	%-HARHA	0,5	0,6	5,5

Kokonaistilavuuden ennustamisessa k-MSN-menetelmän tarkkuus heikkeni selvästi puun koon kasvaessa (kuvat 10 & 11). Menetelmän tuottamat kokonaistilavuus-ennusteet eivät enää olleet Kiihtelysvaarassa yhtä selviä ja järjestelmällisiä aliarvioita kuin aiempien tunnusten tapauksissa, vaan havainnot ovat jokseenkin tasaisemmin jakautuneet nollaviivan molemmin puolin. Tosin ennustetun tilavuuden kasvaessa yli kuutiometriin on vaihtelu jo erittäin suurta, ja varsinkin Kolin aineistossa tämän kokoluokan puille tehdyt ennusteet ovat lähes pelkästään yliarvioita.



Kuva 10. k-MSN-mallin tuottamat jäännöskuvaajat kokonaistilavuuden suhteen.



Kuva 11. k-MSN-mallin tuottamat hajontakuvaajat kokonaistilavuuden suhteen.


3.1.5 Teorettinen tukkitilavuus

Versio 2 osoittautui hieman tarkemmaksi myös tukkitilavuuden ennustamisessa, tosin Kiihtelysvaaran ja Kolin aineistoissa versioiden väliset erot olivat erittäin pieniä (taulukko 8). Liperin datan suhteellinen RMSE oli 38,7 %. Kiihtelysvaarassa lukema kasvoi arvoon 56,2 % ja Kolille siirryttäessä arvoon 53,0 %. Teorettinen tukkitilavuus oli siis tutkimuksen ainoa tunnus, jonka ennustaminen k-MSN-menetelmällä onnistui tarkemmin Kolilla kuin Kiihtelysvaarassa.


Taulukko 8. k-MSN-mallien tuottamat RMSE- ja harha-arvot teoreettisen tukkitilavuuden suhteen eri tutkimusalueilla.

		Liperi	Kiihtelysvaara	Koli
Versio 1	RMSE (I)	166,0	155,6	208,3
	%-RMSE	39,7	56,3	53,9
	HARHA (I)	-1,7	10,2	-6,8
	%-HARHA	-0,4	3,7	-1,8
Versio 2	RMSE (I)	162,2	155,5	204,7
	%-RMSE	38,7	56,2	53,0
	HARHA (I)	2,9	15,1	27,6
	%-HARHA	0,7	5,5	7,1

Kokonaistilavuuden tavoin myös tukkitilavuutta ennustettaessa jäännösten välinen vaihtelu kasvoi ennustetun tilavuuden kasvaessa (kuvat 12 & 13). Menetelmä toimi varsin hyvin aina n. 0,75 m³:n ennusteisiin asti, mutta sen jälkeen erityisesti Kolin aineistossa jäännökset levisivät yhä laajemmalle nollaviivan alapuolelle osoittaen menetelmän tuottaneen jälleen yliarvioita. Kiihtelysvaarassa yli-/aliarvioiden syntyminen ei ollut niin ilmeistä.



Kuva 12. k-MSN-mallin tuottamat jäännöskuvaajat tukkitilavuuden suhteen.



Kuva 13. k-MSN-mallin tuottamat hajontakuvaajat tukkitilavuuden suhteen.

3.2 Lineaariset regressiomallit

Myös tunnuskohtaisissa lineaarisissa regressiomalleissa (kaavat 7-11) käytettiin selittävinä tekijöinä pelkästään laserkeilaustunnuksia. Kuhunkin malliin sisällytettiin yhteensä 2-3 selittäjää, ja intensiteettitunnuksista vain suhteelliset tunnukset olivat hyväksyttäviä. Lineaariset regressioyhtälöt ovat yleisesti kaavan 6 kuvaamaa muotoa.

$$y = i_1 + i_2\alpha_1 + i_3\alpha_2 + i_4\alpha_3 \dots + \varepsilon_i \quad (6)$$

jossa

y = haluttu tunnus

i_j = vakiokerroin

α_i = selittäjä

ε_i = virhetermi

Mallit olivat sopeutetuilta selitysasteiltaan melko vaihtelevia, mutta silti varsin onnistuneita: selitysasteet vaihtelivat läpimittamallin arvon 0,60 ja pituusmallin arvon 0,97 välillä (taulukko 9). F-testin p-arvo oli kaikilla malleilla $<2,2e^{-16}$.

Taulukko 9. Tunnuskohtaisten lineaaristen regressiomallien tunnusluvut. RMSE- ja harha-arvot koskevat siis vain mallitusdataa eli Liperin aineistoa. Kokonais- ja tukkitilavuusmallien tuottamia keskivirhearvoja (lihavoitu) käytettiin kyseisten mallien harhankorjauksessa. Selitysaste on ”sopeutettu” selitysaste eli adjusted R².

Tunnus	Lpm (cm)	Pituus (m)	Latvusraja (m)	V _{KOK.} (l)	V _{TUKKI} (l)
Keskivirhe	3,16	0,63	1,60	0,224	3,243
Selitysaste	0,60	0,97	0,78	0,81	0,78
RMSE	3,15	0,63	1,59	128,50	143,39
%-RMSE	12,71	2,97	12,01	25,34	34,24
HARHA	-6E-17	1,35E-17	0	0,41	0,04
%-HARHA	-2E-16	6,38E-17	0	0,08	0,01

3.2.1 Läpimitta

Puun rinnankorkeusläpimitalle luotu LR-malli sisälsi sekä korkeus- että intensiteettitunnuksia (kaava 7). Läpimittamallin suora mallitarkkuus oli senttimetreinä 3,2 ja prosentteina 12,7 (taulukko 10). Kiihtelysvaaraan siirrettäessä mallin suhteellinen RMSE kasvoi 13,9 prosenttiin, ja Koliille siirrettäessä 17,2 prosenttiin. Molemmilla alueilla harhat olivat nollaa suurempia ja Koliilla jo lähes 4,5 %.

$$Lpm (cm) = \quad (7)$$

$$9,9489401 + 1,0743033 * H95TH_f - 0,1128046 * ICV_f$$

$$- 0,6051316 * ISKE_l$$

jossa

H95TH_f = Korkeuden 95. persentiili (ensimmäiset pulssit)

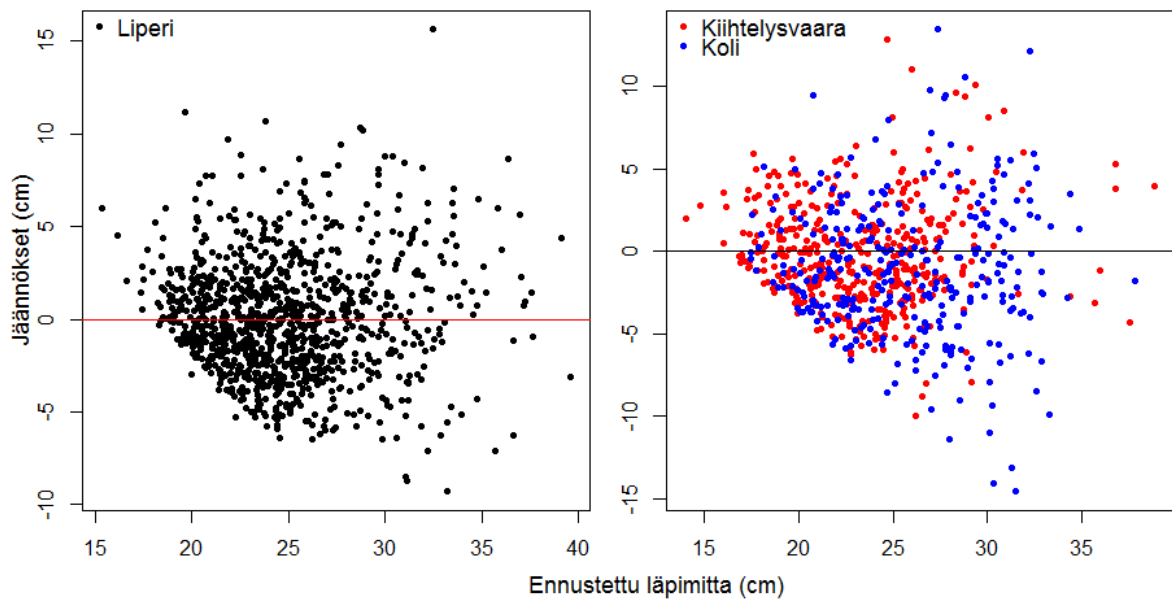
ICV_f = Intensiteetin variaatiokerroin (ensimmäiset kaiut)

ISKE_l = Intensiteettijakauman vinous (viimeiset kaiut)


Taulukko 10. Lineaarisen regressiomallin tuottamat RMSE- ja harha-arvot läpimitan suhteen eri tutkimusalueilla.

Alue	Liperi	Kiihtelysvaara	Koli
RMSE (cm)	3,2	3,2	4,2
%-RMSE	12,7	13,9	17,2
HARHA (cm)	0,0	0,3	1,1
%-HARHA	0,0	1,1	4,5

Mallinnusvaiheessa läpimittamalliin kokeiltiin erilaisia muunnoksia, mutta ne eivät parantaneet mallia. Liperin aineistossa malli toimikin varsin hyvin, sillä jäännökset jakoutuivat melko tasaisesti nollaviivan molemmin puolin (kuva 14), olipa ennustettu arvo kuinka suuri tahansa. Sen sijaan Kolilla, varsinkin tapauksissa missä ennustettu läpimitta oli suurempi kuin 25 cm, jäännökset alkoivat kuitenkin levitä laajalle ja malli tuotti myös karkeita virhearvioita molempiin suuntiin. Esimerkiksi jäännöskuvaajan alalaidassa on kolme irrallista hieman yli 30 cm ennustetta, jotka kaikki ovat lähes 15 cm yliarvioita. Tosin vastapainoksi löytyy myös muutama yli 10 cm aliarviokin.



Kuva 14. Lineaarisen regressiomallin tuottamat jäännöskuvaajat läpimitan suhteen.



Kuva 15. Lineaarisen regressiomallin tuottamat hajontakuvaajat läpimitan suhteen.

Kiihtelysvaarassa malli toimi puolestaan selvästi tarkemmin: yli 7 cm virhearvioit ovat vain yksittäisiä kappaleita ja jopa yli 35 cm ennusteiden virheet ovat nekin kaikki aika lailla alle 5 cm. Hajontakuvaajien (kuva 15) nollaviivan alapuolisista muodoista näkyy selvästi myös se, että mukana oli vain rinnankorkeuslähimitaltaan yli 16 senttimetrisiä puita.

3.2.2 Pituus

Puun pituudelle luodussa LR-mallissa oli mukana vain kaksi selittäjää (kaava 8). Malli itse asiassa toimi hyvin jo pelkästään yhdellä korkeustunnuksella, mutta yhden suhteellisen intensiteettitunnuksen mukaan ottaminen toiseksi selittäjäksi osoittautui kuitenkin parantavan mallia hieman, joten sekin otettiin mukaan selittäjäksi.

$$Pituus (m) = \quad \quad \quad (8)$$

$$1,69359225 + 0,97778021 * H95TH_f + 0,05466027 * IKUR_p$$

jossa

H95TH_f = Korkeuden 95. persentiili (ensimmäiset pulssit)

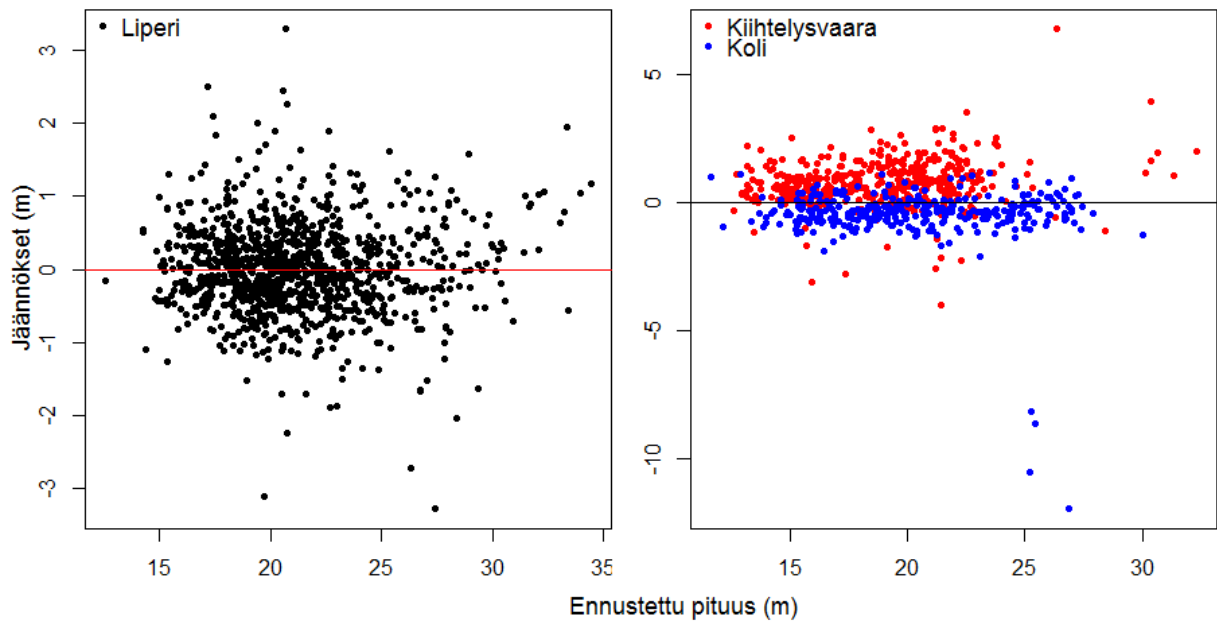
IKUR_p = Intensiteettijakauman huipukkuus (koealataso)

Pituusmallin suora mallitarkkuus oli 0,63 metriä ja 2,97 % (taulukko 11). Siirto muille tutkimusalueille heikensi mallin toimivuutta selvästi: tarkkuus osoittautui Kiihtelysvaarassa ja Kolilla lähes puolet heikommaksi. Tosin suhteellinen RMSE oli silti molemmilla alueilla vain hieman yli 6 %, mikä sekin on vielä hyvä tarkkuus ennusteille. Kiihtelysvaarassa harhat olivat negatiivisia (-0,76 m / -3,87 %) ja Kolilla positiivisia (0,47 m / 2,35 %).


Taulukko 11. Lineaarisen regressiomallin tuottamat RMSE- ja harha-arvot pituuden suhteen eri tutkimusalueilla.

Alue	Liperi	Kiihtelysvaara	Koli
RMSE (m)	0,63	1,20	1,28
%-RMSE	2,97	6,15	6,42
HARHA (m)	1,4E-17	-0,76	0,47
%-HARHA	6,4E-17	-3,87	2,35

Mallin tarkkuus ei käytännössä juurikaan heikentynyt ennustetun pituuden kasvaessa, mutta puun pituuden ollessa yli 30 metriä, näyttäisi malli olevan taipuvainen tuottamaan pieniä aliarvioita (kuvat 16 & 17). Myös näistä kuvaajista on harhojen etumerkkien ohella helppo havaita Kiihtelysvaarassa syntyneet aliarviot ja Kolilla syntyneet yliarviot. Jäännöskuvaajassa Kolin pisteet ovat neljää selvästi poikkeavaa havaintoa lukuun ottamatta erittäin tiiviisti nollaviivan tuntumassa, kun taas Kiihtelysvaaran pisteet ovat lähtökohtaisesti leveämmin, mutta ilman suurempia virhearvioita enimmäkseen nollaviivan yläpuolella.



Kuva 16. Lineaarisen regressiomallin tuottamat jäännöskuvaajat pituuden suhteen.



Kuva 17. Lineaarisen regressiomallin tuottamat hajontakuvaajat pituuden suhteen.

3.2.3 Latvusraja

Puun latvusrajaa ennustavaan LR-malliin otettiin mukaan kaksi korkeustunnusta sekä yksi suhteellinen intensiteettitunnus (kaava 9). Suora mallitarkkuus oli 1,59 m / 12,01 % (taulukko 12). Mallin siirto Kiihtelysvaaraan heikensi suhteellista RMSE:tä vain hieman yli prosenttiyksiköllä, mutta Kolilla ennusteet olivat huomattavasti epätarkempia, sillä suhteellinen RMSE oli siellä lähes 20 %. Harhat olivat näillä alueilla jälleen etumerkeiltään erilaisia.

$$\text{Latvusraja (m)} = \quad (9)$$

$$-1,3560214 + 0,8184224 * \text{HMEDIAN}_f + 1,0071082 * \text{ISKE}_f + 0,1383651 * \text{H30TH}_p$$

jossa

HMEDIAN_f = Korkeuksien mediaani (ensimmäiset kaiut)


ISKE_f = Intensiteettijakauman vinous (ensimmäiset kaiut)

H30TH_p = Korkeuden 30. persentiili (koealataso)


Taulukko 12. Lineaarisen regressiomallin tuottamat RMSE- ja harha-arvot latvusrajan suhteen eri tutkimusalueilla.

Alue	Liperi	Kiihtelysvaara	Koli
RMSE (m)	1,59	1,45	2,20
%-RMSE	12,01	13,16	19,63
HARHA (m)	0	-0,54	0,85
%-HARHA	0	-4,91	7,61

Myöskään tällä mallilla ei ilmennyt Liperin datassa heteroskedastisuutta (kuva 18). Kuitenkin Kolilla jäännösten vaihtelu alkoi jälleen selvästi kasvamaan ennustetun latvusrajan ylittäessä n. 10 m rajan, ja suurilla ennustetuilla arvoilla malli oli taipuvainen tuottamaan yhä selvemmin yliarvioita. Sen sijaan Kiihtelysvaarassa mallin tarkkuuden heikkeneminen ennustetun arvon kasvaessa oli selvästi vähäisempää, eikä aliarvioidenkaan syntyminen ollut niin ilmeistä (kuva 19).



Kuva 18. Lineaarisen regressiomallin tuottamat jäännöskuvaajat latvusrajan suhteen.



Kuva 19. Lineaarisen regressiomallin tuottamat hajontakuvaajat latvusrajan suhteen.

3.2.4 Kokonaistilavuus

Kokonaistilavuutta selittävässä LR-mallissa selittäjänä oli korkeus- ja intensiteettitunnuksen lisäksi latvuksen itä-länsisuuntaista leveyttä ilmentävä selittäjä (kaava 10). Laserkeilausdatasta laskettiin latvuksille myös vastaava pohjois-eteläsuuntainen tunnus, mikä korreloi erittäin vahvasti itä-länsisuuntaisen leveyden kanssa. Siispä latvuksen suurempi itä-länsisuuntainen leveys tarkoittaa myös suurempaa pohjois-eteläsuuntaista leveyttä, joten tunnus käytännössä

korreloi koko latvuksen ylhäältä päin katsotun pinta-alan kanssa. Tunnus on siten käyttökel-poinen selittäjä tilavuusmalleissa, sillä suurempi latvuksen pinta-ala tarkoittaa pidempiä, le-veämpiä ja tuuheampia oksia, mistä taas lähtökohtaisesti seuraa se, että myös itse puun run-kotilavuuskin on yleensä suurempi.

$$V_{Kok.}(l) = \exp(3,3240160 + 0,3406785 * \log(EWIDTH_f) - 0,2517903 * ISKE_f + 0,1142954 * HMAX_l + \frac{a^2}{2}) \quad (10)$$

jossa

EWIDTH_f = latvuksen leveys (ensimmäiset kaiut)

ISKE_f = Intensiteettijakauman vinous (ensimmäiset kaiut)

HMAX_l = Korkeuksien maksimi (viimeiset kaiut)

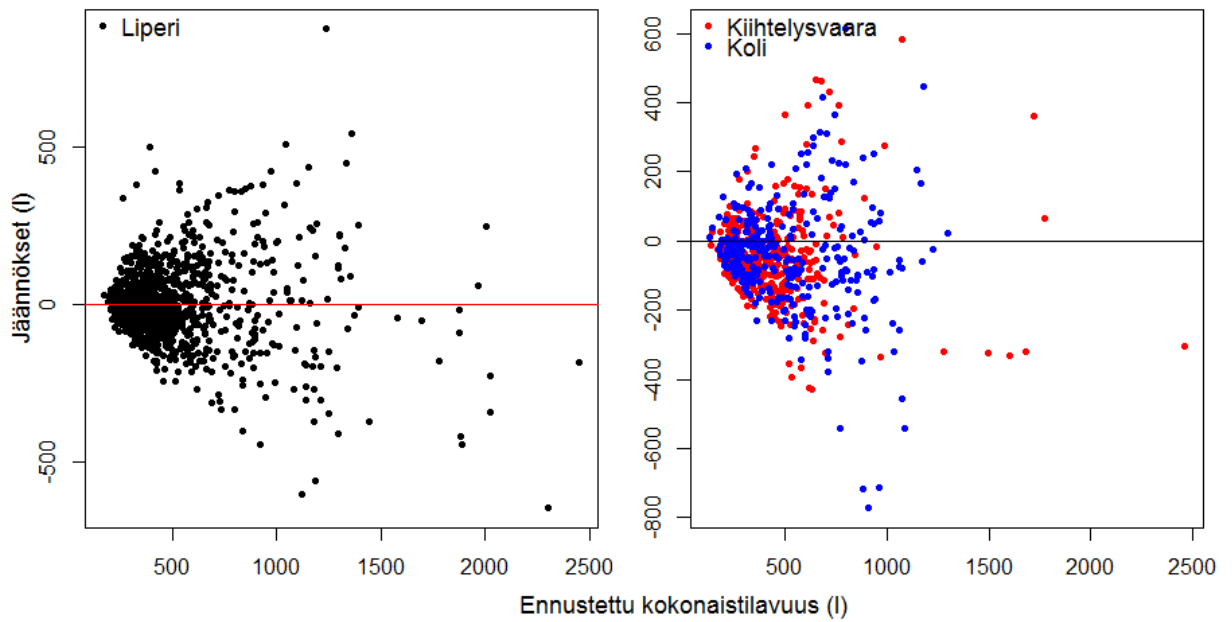
$\frac{a^2}{2}$ = Logaritmimuunnoksen harhankorjaustermi (a = 0,224; taulukko 9)

Kokonaistilavuutta ennustavaan malliin tehtiin mallinnusvaiheessa logaritmimuunnos, mistä johtuen tunnusta ennustavassa laskutoimituksessa oli mukana harhankorjaustermi $\frac{a^2}{2}$, jossa a oli mallin keskivirhe (taulukko 9). Lisäksi yhtälön koko oikeasta puolesta otettiin logaritmin kumoava eksponentti. Mallin RMSE oli 128,5 litraa ja suhteellinen RMSE 25,3 % (taulukko 13). Kiihtelysvaaraan siirrettäessä suhteellinen RMSE kasvoi 35,5 prosenttiin, ja Kolilla 34,4 prosenttiin. Kokonaistilavuus oli siis tähän mennessä käsitellyistä tunnuksista ensimmäinen, jonka ennustaminen lineaarisella regressioanalyysillä onnistui Kolilla suhteellisesti paremmin kuin Kiihtelysvaarassa. Malliin lisätyn harhankorjaustermin myötä Kiihtelysvaaran ja Kolin tarkkuudet heikkenivät entisestään, sillä ilman harhankorjaustermiä lasketut RMSE-arvot olivat Kiihtelysvaarassa 129,6 litraa/34,5 % ja Kolilla 159,0 litraa/33,7 %. Harhankorjaustermin lisäämisen myötä malli tuotti siis molemmilla testausalueilla yhä enemmän yliarvioita.


Taulukko 13. Lineaarisen regressiomallin tuottamat RMSE- ja harha-arvot kokonaistilavuuden suhteen eri tutkimusalueilla.

Alue	Liperi	Kiihtelysvaara	Koli
RMSE (l)	128,5	133,2	162,5
%-RMSE	25,3	35,5	34,4
HARHA (l)	0,4	47,8	42,8
%-HARHA	0,1	12,7	9,1

Ilman logaritimuunnosta malli tuotti suurilla ennustetuilla arvoilla yhä suurempia aliarvioita, eli jäännöspiste-parvi kaareutui selvästi nollaviivan yläpuolelle. Muunnoksen avulla jäännökset saatiin jakautumaan melko tasaisesti nollaviivan molemmin puolin, mutta malliin jäi edelleen väistämättä selvää heteroskedastisuutta (kuva 20). Suurilla ennustetuilla arvoilla ($> 1,5 \text{ m}^3$) malli tuotti lisäksi selvemmin yli- kuin aliarvioita.



Kuva 20. Lineaarisen regressiomallin tuottamat jäännöskuvaajat kokonaistilavuuden suhteen.



Kuva 21. Lineaarisen regressiomallin tuottamat hajontakuvaajat kokonaistilavuuden suhteen.

Siirto Kiihtelysvaaraan tai Kolille ei näkynyt jäännöskuvaajien muodossa dramaattisesti, mutta jäännösten vaihtelu oli jo heti pienillä ennustetuilla tilavuuksilla hieman suurempaa ja Kolilla suurimmat yksittäisetkin virheet olivat lähes 800 litran luokkaa. Mallin yliarvioiden tuottaminen Kiihtelysvaaran ja Kolin alueilla näkyy melko selvästi myös näistä kuvaajista, sillä molempien alueiden pisteet ovat painottuneet enemmän sekä jäännöskuvaajan nollaviivan, että hajontakuvaajan $x=y$ -viivan alapuolelle (kuva 21).

3.2.5 Teorettinen tukkitilavuus

Kokonaistilavuusmallissa ollut latvuksen leveyttä kuvaava lasertunnus sisällytettiin myös tukkitilavuutta ennustavaan lineaariseen regressiomalliin (kaava 11). Sen lisäksi mallissa oli yksi korkeus- ja yksi suhteellinen intensiteettitunnus. Tukkitilavuusmalliin tehtiin neliöjuurimuunnos, mistä johtuen yhtälön oikea puoli korotettiin toiseen potenssiin. Muodostuneeseen summaan lisättiin vielä harhankorjaustermi b^2 , jossa b oli mallin keskivirhe (taulukko 9).

$$V_{Tukki}(l) = \left(-14,788704 + 1,516898 * H95TH_f + 1,092384 * EWIDTH_f - 3,832631 * ISKE_f \right)^2 + b^2 \quad (11)$$

jossa

H95TH_f = Korkeuden 95. persentiili (ensimmäiset pulssit)

EWIDTH_f = latvuksen leveys (ensimmäiset kaiut)

ISKE_f = Intensiteettijakauman vinous (ensimmäiset kaiut)

b^2 = Neliöjuurimuunnoksen harhankorjaustermi ($b = 3.243$; taulukko 9)


Teoreettisen tukkitilavuuden ennustaminen ei onnistunut lähellekään niin tarkasti kuin kokonaistilavuuden ennustaminen: mallin absoluuttinen RMSE oli 143,4 litraa ja suhteellinen RMSE 34,2 prosenttia (taulukko 14). Siirron myötä tarkkuus heikkeni edelleen, ja suhteellinen RMSE oli Kiihtelysvaarassa jo 56,5 %. Kolilla tarkkuus ei heikentynyt näin paljoa, sillä suhteellinen RMSE oli 47,1 % - LR-mallilla myös tukkitilavuuden ennustaminen onnistui siis Kolilla suhteellisesti tarkemmin kuin Kiihtelysvaarassa. Neliöjuurimuunnoksen harhankorjaustermi kasvatti mallin epätarkkuutta testialueilla, sillä malli tuotti jo ennestäänkin yliarvioita. Harhankorjaustermin myötä kuhunkin ennusteeseen lisättiin vielä arvo $3,243^2$ eli n. 10,5 litraa, mikä siis edelleen kasvatti yliarvioita.

Taulukko 14. Lineaarisen regressiomallin tuottamat RMSE- ja harha-arvot tukkitilavuuden suhteen eri tutkimusalueilla.

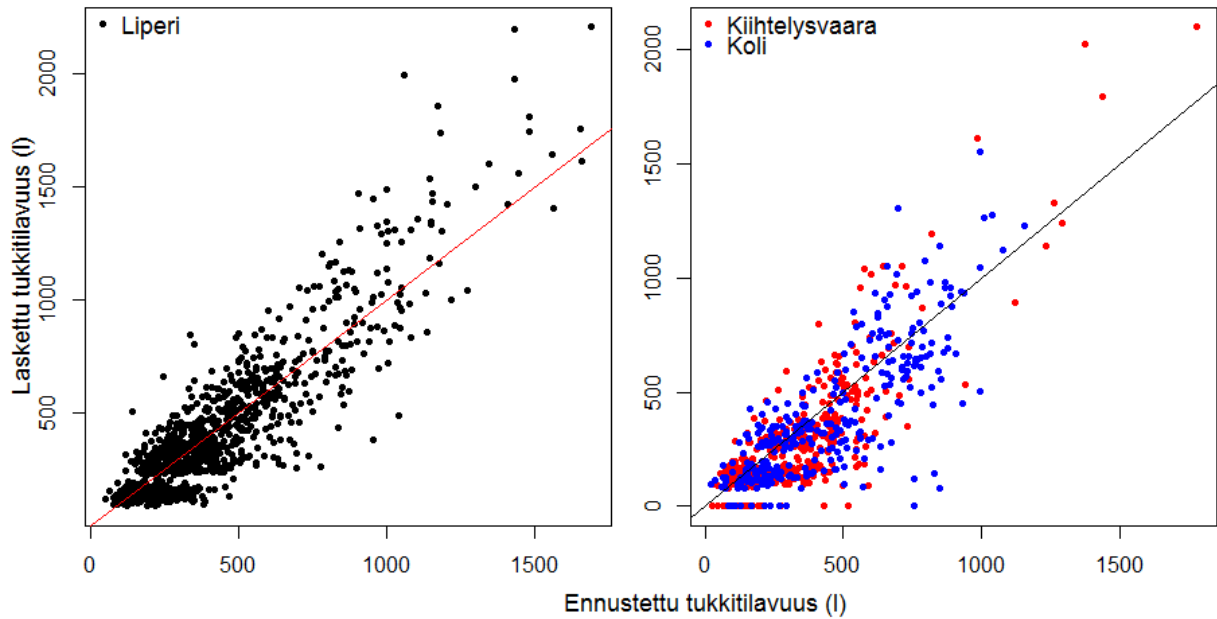
Alue	Liperi	Kiihtelysvaara	Koli
RMSE (l)	143,4	156,3	182,0
%-RMSE	34,2	56,5	47,1
HARHA (l)	0,0	50,7	48,2
%-HARHA	0,0	18,3	12,5

Neliöjuurimuunnoksella saatiin parannettua mallin jäännöskuvaajaa huomattavasti, mutta muunnoksesta huolimatta malliin jäi heteroskedastisuutta ja hieman epälinearisuuttakin (kuvat 22 & 23). Ennustetun tukkitilavuuden kasvaessa jäännökset alkoivat varsin selvästi nousemaan nollaviivan yläpuolelle, mikä siis tarkoitti, että suurilla ennustetuilla arvoilla malli aliarvioi tukkitilavuutta.

Kiihtelysvaaran ja Kolin aineistoissa malli käyttäytyi hieman eri tavoin. Kiihtelysvaarassa ennustetun tukkitilavuuden kasvaessa mallin ennusteet olivat enemmän aliarvioita, kun taas Kollilla niin suurien, kuin keskikokoistenkin ennusteiden tilavuudet olivat enemmän yliarvioita. Kuitenkin myös Kiihtelysvaarassa suurin osa jäännöksistä sijoittui nollaviivan alapuolelle, eli pienillä ja keskisuurilla ennusteilla malli tuotti sielläkin enemmän yliarvioita.



Kuva 22. Lineaarisen regressiomallin tuottamat jäännöskuvaajat tukkitilavuuden suhteen.



Kuva 23. Lineaarisen regressiomallin tuottamat hajontakuvaajat tukkitilavuuden suhteen.

4 TULOSTEN TARKASTELU

Tutkimuksen tavoitteena oli selvittää laserkeilauspohjaisten mallien siirrettävyyttä, eli sitä kuinka paljon yhden mallitusaineiston pohjalta laadittujen k-MSN -menetelmän ja lineaaristen regressiomallien tuottamien puustoennusteiden tarkkuus heikkenee, kun malleja sovelletaan täysin erillisiin aineistoihin. Aiempiin tutkimuksiin pohjautuneiden ennako-odotusten mukaisesti ennusteiden tarkkuus todella heikkeni siirtojen seurauksena kaikissa tapauksissa. Kuitenkin tarkkuuksien heikkeneminen oli enimmäkseen melko vähäistä, ja muutamissa tapauksissa ero mallitus- ja validointidatojen välillä oli tutkimuksen lähtökohdat huomioiden pieni. Koska eri aineistot poikkesivat puustoiltaan toisistaan, suoritetaan tulosten tarkastelu ensisijaisesti suhteellisten RMSE-arvojen pohjalta.

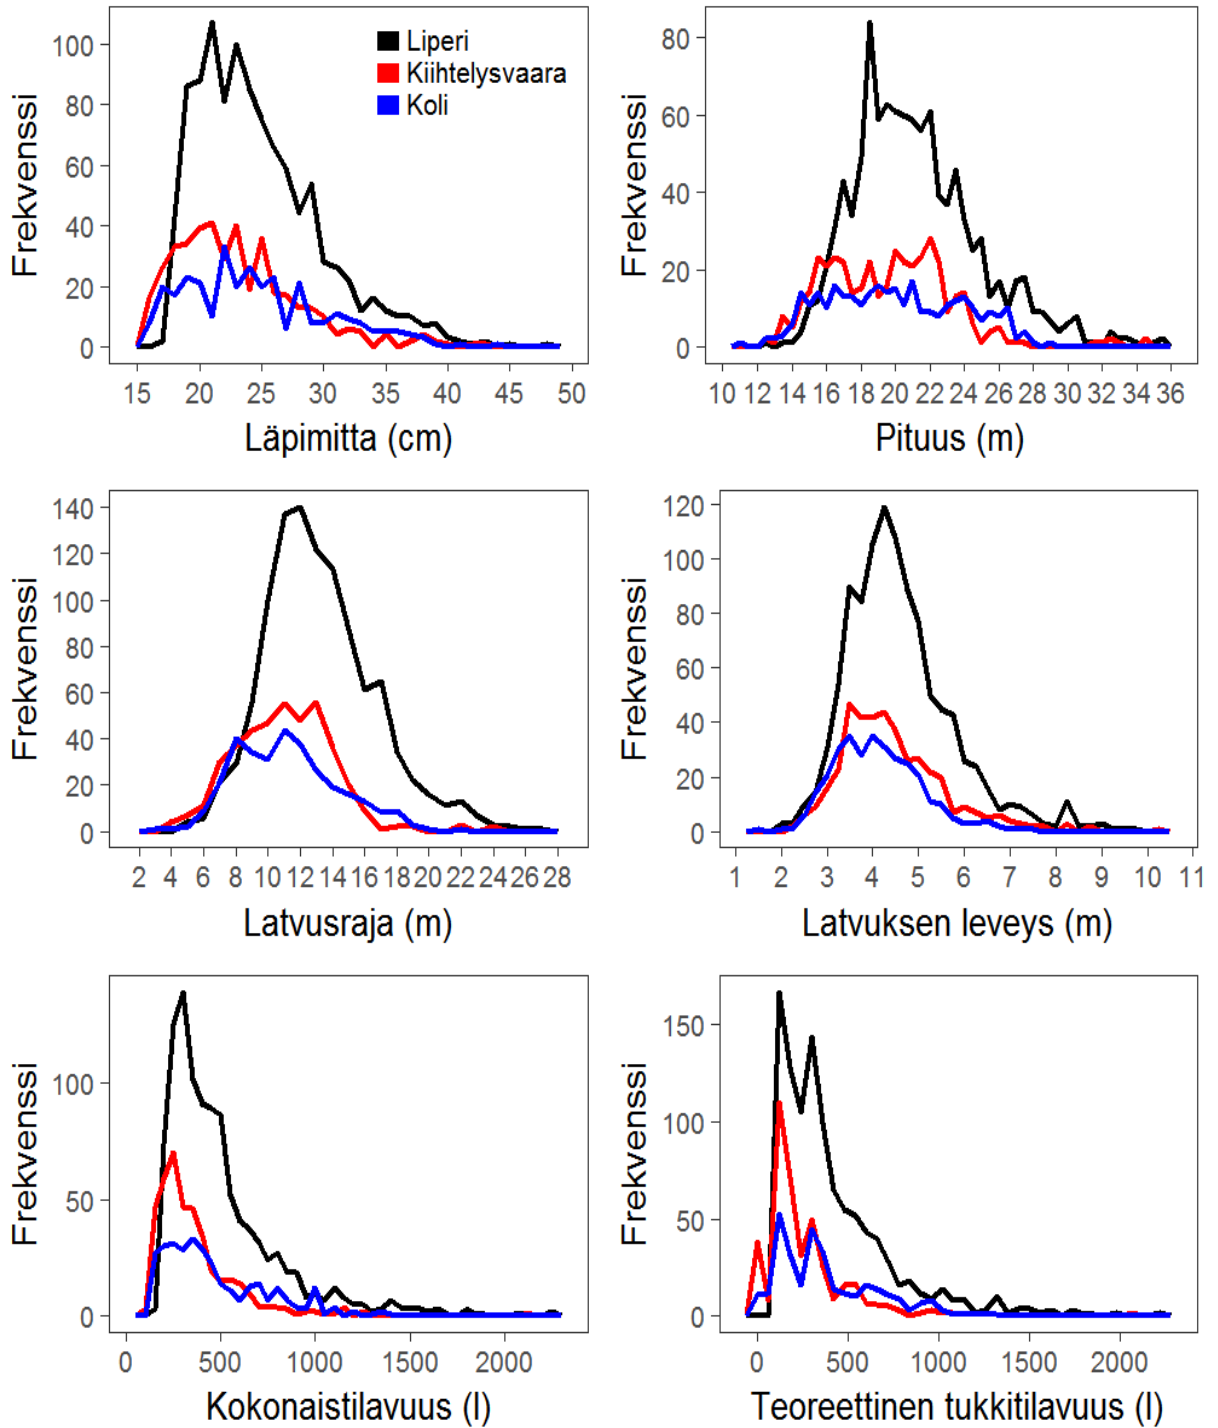
Ennusteiden epätarkentuminen johtuu siis eroavaisuuksista itse laserkeilauksen yksityiskohdissa ja/tai puuston rakenteessa tutkimusalueiden välillä. Tässä tutkimuksessa eri alueiden keilaukset poikkesivat toteutuksiltaan toisistaan hyvin paljon, niin käytettyjen keilainlaitteiden, kuin myös keilausparametrienkin suhteen. Käytettyjen keilausparametrien erilaisuudesta aiheutuneita todellisia vaikutuksia ennusteisiin ei kuitenkaan ilman minkäänlaisia vertailukohtia pystytty tässä tutkimuksessa arvioimaan. Ainoastaan keilauksessa saavutetun pistetiheyden varaan voi sillä oletuksella rakentaa johtopäätöksiä, että korkeampi pistetiheys tarkoittaa

korkealaatuisempaa aineistoa, ja siten johtaa parempiin tarkkuuksiin myös puupolygoneista irrotettujen laserpiirteiden ja niihin yhdistettävien maastossa mitattujen tunnusten välisten riippuvuuksien välillä – ja näin ollen siis myös itse ennusteet ovat yksinpuintasolla todennäköisesti tarkempia (Persson ym., 2002). Lisäksi keilauksien suhteen täytyy muistaa, ettei maljeissa heikon siirrettävyyden vuoksi käytetty intensiteettitunnuksista muita kuin intensiteettien jakaumaa kuvaavia huipukkuutta, vinoutta ja variaatiokerrointa. Selvästi enemmän käytettyjen korkeustunnusten ei ainakaan lähtökohtaisesti pitäisi yksinpuintasolla olla luonteeltaan kovinkaan erilaisia eri alueilla, vaikka keilain ja keskimääräinen puusto vaihtuisivatkin.

Yksinpuintulkinnassa puuston rakenteelliset eroavaisuudet eri alueiden välillä eivät todennäköisesti ole niin suuria ja merkittäviä kuin mitä ne aluepohjaisessa menetelmässä olisivat. Myöskään metsikön pohjapinta-alalla ja puiden keskinäisellä tilajärjestyksellä ei ole niin kauaa merkitystä, kun yksittäiset puut vain saadaan segmentoitua luotettavasti. Tässä tutkimuksessa segmentoinnin onnistumista edesauttoi se, että tarkastelun kohteena oli vain suuria, vallitsevan latvuskerroksen tukkikokoisia mäntyjä. Tosin eri tutkimusalueilla saavutettuja tarkkuuksia vertailtaessa täytyy muistaa, että Kolilla koealat sijaitsivat kansallispuiston alueella, eli harvennushakkuuta ei oltu suoritettu ainakaan viimeiseen 15 vuoteen ennen mittausajankohtaa. Hoitamattomuudesta seurannut oletamus siitä, että Kolin mäntyjen latvustot olisivat hieman suppeampia näytti myös pitävän paikkansa, sillä esim. latvuksen leveyttä kuvaavan EWIDTH_f-tunnuksen keskiarvo oli Liperissä 4,59 m, Kiihtelysvaarassa 4,43 m ja Kolilla 4,11 m. Eroavaisuudet olivat samassa linjassa myös muiden latvuksen leveyttä kuvaavien tunnusten suhteen, tosin täytyy muistaa, että Kolilla myös pistetiheys oli alhaisempi eli ALS-pohjainen leveystunnus ei välttämättä itsessäänkään ollut Kolilla niin tarkka kuin Liperissä tai Kiihtelysvaarassa. Kuitenkin ottaen huomioon, että Kolilla mäntyjen keskiläpimitta ja -pituus olivat kuitenkin suurempia kuin Kiihtelysvaarassa, vaikuttaisi siis siltä, että Kolilla latvukset todella olivat ainakin pinta-alallisesti hieman pienempiä suhteessa muuhun runkoon kuin Liperissä tai Kiihtelysvaarassa.

Havaitut eroavaisuudet latvusten leveyksissä olivat kuitenkin pieniä, joten hoitamattomuuden todellista vaikutusta yksittäisten puiden ominaisuuksiin ja edelleen Kolin ennusteiden tarkkuuksiin on vaikea arvioida tarkasti. Lisäksi Liperin aineisto oli laaja, ja se kattoi vertailualueiden puustolliset vaihtelut hyvin (kuva 24): Mikäli siis k-MSN-menetelmässä käytettyjen ALS-tunnusten ja mitattujen puustotunnusten riippuvuussuhteiden välillä oli edes jonkinasteista korrelaatiota eri tutkimusalueiden välillä, niin todennäköisesti myös referenssidatasta löytyi

kullekin niin Kiihtelysvaaran kuin Kolinkin kohdepuulle todellisuudessaakin varsin samankaltaisia naapureita, joista halutut tunnuksedelleen ennustettiin. Aivan vastaavasti mallitusaineiston kattavuus todennäköisesti paransi myös lineaaristen regressiomallien tarkkuuksia.



Kuva 24. Puiden frekvenssijakaumat eri tunnusten suhteen eri tutkimusalueilla. Latvuksen leveys on johdettu latvuksen ensimmäisten kaikujen osumista. Puumäärät: Liperi 1051, Kiihtelysvaara 414, Koli 317 kpl.

4.1 Mallitusaineistossa saavutetut tarkkuudet

k-MSN-menetelmällä kokeilluista selittäjäyhdistelmistä siis versio 2, jossa oli mukana myös kaksi intensiteettitunnusta, tuotti hieman parempia ennusteita mallitusaineistossa kaikkien muiden tunnusten paitsi pituuden suhteen, mikä sinänsä oli ihan odotettua, sillä pituus voidaan ennustaa luotettavasti suoraan jo pelkistä korkeustunnuksista. Kuitenkin pituuden RMSE oli 1. versiossa vain yhden senttimetrin pienempi, eli intensiteettien läsnäolo selittäjäjoukossa ei myöskään epätarkentanut ennustetta.

Alkuperäisellä, mutta hylätyllä 5 korkeus- ja 5 intensiteettitunnusta sisältäneellä selittäjäjoukolla päästiin läpimitan (RMSE 12,2 %), kokonaistilavuuden (26,5 %) ja tukkitilavuuden (34,7 %) ennustamisessa jonkin verran parempiin tarkkuuksiin kuin tutkimuksessa lopulta käytetyillä kahdella versiolla. Edellä mainituilla tunnuksilla ja intensiteeteillä oli siis luonnossa jonkinlainen yhteys – vastaavasti pituuden (3,3 %) ja latvusrajan (13,5 %) ennusteet olivat viidellä intensiteettiselittäjällä hieman heikompia. Siirtojen jälkeen nämä 5 intensiteettiselittäjää sisältäneet ennusteet olivat kuitenkin huomattavasti, joissain tapauksissa jopa yli kaksinkertaisesti epätarkempia tutkimuksessa lopulta käytettyihin versioihin verrattuna (liite 2).

k-MSN-menetelmällä läpimitan, pituuden, latvusrajan, kokonaistilavuuden ja tukkitilavuuden ennustaminen onnistui parhaimmillaan siis Liperin mallitusaineistossa suhteellisilla RMSE-arvoilla 13,49 % (2. versio), 3,16 % (1.), 13,00 % (2.), 29,83 % (2.) ja 38,73 % (2.). Maltamo ym. (2009b) saavuttivat samalla menetelmällä Kolin aineiston tukkikokoisille männyille huomattavasti pienemmät RMSE-arvot: läpimita 5,16 %, pituus 1,95 %, latvusraja 7,13 % ja rungon kokonaistilavuus 11,00 %. Teoreettisen tukkitilavuuden sijaan Maltamo ym. ennustivat rungon suhteellista tukkiosuutta, mikä sekin onnistui 8,73 % RMSE:llä. Osa Maltamon ym. tutkimuksessa luotujen ennusteiden paremmista tarkkuuksista selittynee ainakin sillä, että siinä kaikki tunnuksia ennustettiin erikseen, ts. kaikille tunnuksille valittiin optimaalisimmat selittäjät, kun taas tässä tutkimuksessa tavoitteena oli kaikkien viiden tunnuksen RMSE-arvojen yhtäaikainen minimoiminen yhteisellä selittäjäjoukolla. Lisäksi Maltamo ym. käyttivät huomattavasti laajempia, 20-30 ALS-tunnuksen selittäjäjoukkoja, kun tässä tutkimuksessa selittäjiä oli puolestaan 1. versiossa 5 ja 2. versiossa 7 kappaletta. Myös esim. erilaisista segmentoinneista aiheutui todennäköisesti jonkinasteista eroa ennusteisiin.

Lineaaristen regressiomallien suhteelliset RMSE:t läpimitan, pituuden, latvusrajan, kokonaistilavuuden ja tukkitilavuuden suhteen olivat puolestaan 12,71 %, 2,97 %, 12,01 %, 25,34 % ja 34,24 %, eli ennusteet olivat hieman k-MSN-menetelmän vastaavia tarkempia. Tämä oli ihan

odotettavissa, sillä mallit laadittiin erikseen kullekin puutunnukseksi. Lineaarisia regressiomalleja on sovellettu yksinpuntason tunnusennusteissa vain vähän ja varsinkaan koskien pelkääntään mäntyjä, joten tässä tutkimuksessa saavutetuille mallitarkkuuksille ei löytynyt täysin vertailukelpoisia tuloksia muista tutkimuksista. Kokoluokaltaan tutkimuksen lineaarisilla regressiomalleilla saavutetut tarkkuudet olivat kuitenkin varsin tyyppillisiä ja keskivertaisia yksinpuntaitulkinnan näkökulmasta, vaikka myös selvästi parempiinkin tarkkuuksiin on päästy, joskin siis poikkeavilla menetelmillä ja aineistoilla.

Tutkimuksen ensisijaisena tavoitteena oli kuitenkin selvittää siirrettävyyttä, joten ennusteiden maksimaalisen tarkkuuden saavuttaminen mallitusaineistossa ei siis edes ollut välttämätöntä eikä tarkoituksenmukaista tutkimuksen luonteen kannalta. Esimerkiksi k-MSN-menetelmällä olisi erittäin todennäköisesti voitu saavuttaa tarkempiakin ennusteita vaikkapa juuri ennustamalla tunnuksot erikseen käyttäen optimaalisimpia selittäjiä, mutta se olisi vastavuoroisesti monimutkaistanut siirrettävyyden tutkimista.

4.2 Siirron vaikutus ennusteiden tarkkuuksiin ja menetelmien eroavaisuudet

Yhteenveto eri tutkimusalueilla saavutetuista suhteellisista RMSE-arvoista löytyy taulukosta 15. Taulukossa 16 puolestaan siirtojen vaikutus Kiihtelysvaaran jo Kolin aineistoihin muutosprosentilla ilmaistuna: pienempi arvo tarkoittaa vähäisempää siirrosta aiheutunutta suhteellisen RMSE:n heikkenemistä.

Taulukko 15. Yhteenveto eri alueilla eri menetelmillä saavutetuista suhteellisista RMSE-arvoista (%). k-MSN-sarakeissa tunnuksittain ensin 1. versio, sitten 2. versio.

	Liperi		Kiihtelysvaara		Koli	
	LR-malli	k-MSN	LR-malli	k-MSN	LR-malli	k-MSN
Läpimitta	12,71	13,71 13,49	13,89	15,01 14,48	17,16	18,53 18,02
Pituus	2,97	3,16 3,23	6,15	5,99 6,73	6,42	6,97 6,79
Latvusraja	12,01	13,33 13,00	13,16	15,69 15,84	19,63	23,09 19,24
Kokonaistilavuus	25,34	30,69 29,83	35,5	36,63 36,69	34,39	40,98 40,18
Tukkitilavuus	34,24	39,65 38,73	56,49	56,26 56,2	47,1	53,91 52,98

Taulukko 16. Siirroista aiheutuneet suhteellisen RMSE:n muutosprosentit. Arvo siis kertoo, kuinka monta prosenttia suurempi se on verrattuna Liperin aineistossa havaittuun vastaavaan arvoon. k-MSN-sarakkeissa tunnuksittain ensin 1. versio, sitten 2. versio.

	Kiihtelysvaara		Koli	
	LR-malli	k-MSN	LR-malli	k-MSN
Läpimitta	9,3	9,5 7,3	35,0	35,2 33,6
Pituus	107,1	89,6 108,4	116,2	120,6 110,2
Latvusraja	9,6	17,7 21,8	63,4	73,2 48,0
Kokonaistilavuus	40,1	19,4 23,0	35,7	33,5 34,7
Tukkitilavuus	65,0	41,9 45,1	37,6	36,0 36,8

Läpimitan suhteen menetelmien keskinäiset erot olivat siis varsin pieniä: LR-malli toimi Liperin tavoin myös molemmilla kohdealueilla tarkemmin, mutta molemmilla alueilla sen tarkkuus heikkeni siirrossa hieman enemmän kuin k-MSN-menetelmän 2. versiolla. Siirroista aiheutuneet ennusteiden heikkenemiset olivat kuitenkin Liperissä kokoluokaltaan varsin pieniä: LR-mallin suhteellinen RMSE kasvoi 9,3 % ja k-MSN-menetelmän 2. versio 7,3 %, kun taas Kolilla ennusteet epätarkentuivat huomattavasti enemmän, vastaavien arvojen ollessa 35,0 % ja 33,6 %. Alueiden lopulliset RMSE:t (Kiihtelysvaarassa 13,89 % ja Kolilla 17,16 %) ovat jo kuitenkin huomattavan suuria verrattuna parhaimpiin aiemmissä tutkimuksissa saavutettuihin yksinpuintason läpimittaennusteisiin (esim. Maltamo 2009b). Lisäksi mielenkiintoinen havainto oli, että Kolilla k-MSN-menetelmän 1. versio tuotti aliarvioita, mutta 2. versio puolestaan lähes tulkoon samankokoisia yliarvioita. Vaikka itse tarkkuuksissa ei ollut suuria eroja, vaikutti kahden intensiteettitunnuksen mukaan ottaminen selittäjäjoukkoon kuitenkin siis varsin paljon, muuttaen Kolilla läpimittaennusteen harhan negatiivisesta positiiviseksi (taulukko 4, s. 33).

Pituuden ennustamisessa k-MSN-menetelmän parempien versioiden RMSE-arvot kasvoivat siirtojen yhteydessä Liperiin verrattuna Kiihtelysvaarassa 89,6 % ja Kolilla 110,2 %, ja LR-mallin RMSE:t vastaavasti 107,1 % ja 116,2 %. Eri menetelmien väliset erot olivat jälleen pieniä ja Kiihtelysvaarassa parempi tarkkuus saavutettiin k-MSN-menetelmällä, kun taas Kolilla LR-mallin tuottama ennuste oli hieman tarkempi. Kiihtelysvaarassa juuri parhaan ennusteen tuottanut k-MSN-menetelmän 1. versio selvisi myös siirrosta kaikkein vähäisimmällä epätarkentuomisella, mutta Kolilla k-MSN-menetelmän 2. versio päihitti tässä suhteessa tarkemman ennus-

teen antaneen LR-mallin. Siitäkin huolimatta, että ennusteiden tarkkuus heikkeni siirroissa Liperiin verrattuna lähes/alle puoleen, voi saavutettuja Kiihtelysvaaran 5,99 % sekä Kolin 6,42 % RMSE-arvoja pitää vielä melko tarkkoina pituuden ennustamisessa. Molemmat menetelmät olivat taipuvaisia tuottamaan Kiihtelysvaarassa aliarvioita ja Kolilla yliarvioita.

Lisäksi pituutta ennustettaessa Kolilla k-MSN-menetelmän 2. versio toimi hieman 1. versiota paremmin ja vaikka versioiden välinen tarkkuusero oli vain 0,18 prosenttiyksikköä, on mielenkiintoista, että myös intensiteettitunnuksia sisältänyt 2. versio osoittautui juuri tarkemmaksi vaihtoehdoksi pituutta ennustettaessa, toisin kuin Liperissä ja Kiihtelysvaarassa. Myös tämä havainto kielii siitä, että keilauksessa käytetyillä laitteilla ja parametreilla on merkitystä lopputuloksiin. Vertailukohdaksi vielä mainittakoon, että hylätyllä myös 5 intensiteettitunnusta sisältäneellä selittäjäjoukolla pituusennusteen RMSE oli Kolilla kuitenkin jo 10,08 % ja Liperissäkin muita versioita heikompi, joten yleisesti ottaen intensiteettitunnusten käyttäminen ei tuntunut ainakaan parantavan pituusennusteita.

Latvusrajan tapauksessa k-MSN-menetelmän parempien versioiden suhteelliset RMSE:t kasvoivat Kiihtelysvaarassa 17,7 % ja Kolilla 48,0 %, kun taas LR-mallilla vastaavat muutokset olivat 9,6 % ja 63,4 %. Kiihtelysvaarassa tarkkuusero k-MSN-menetelmän ja LR-mallin välillä oli jo varsin huomattava: suhteelliset RMSE:t olivat 15,69 % (k-MSN 1. versio) vs. 13,16 % (LR-malli). Kolilla puolestaan k-MSN-menetelmän 2.version ja LR-mallin ero ei ollut kuin 0,39 prosenttiyksikköä k-MSN:n hyväksi – pienestä erosta huolimatta LR-mallin harha oli Kolilla yli 3 prosenttiyksikköä k-MSN-menetelmän vastaavaa suurempi. Kolilla latvusrajaennusteet olivat siis jälleen järjestelmällisesti yliarvioita, ja vastaavasti Kiihtelysvaarassa jälleen aliarvioita. Parhaimmillaan latvusrajan ennustaminen onnistui siis Kiihtelysvaarassa 13,16 % ja Kolilla 19,24 % RMSE:llä, joista varsinkin Kiihtelysvaaran lukema (absoluuttinen RMSE 1,45 m) on vielä varsin kohtuullinen saavutus.

Ennustettaessa kokonaistilavuutta, kasvoi k-MSN-menetelmän suhteellinen RMSE siirrossa Kiihtelysvaaraan 19,4 % ja Kolille 33,5 %. LR-mallilla vastaavat luvut olivat 40,1 % ja 35,7 %. LR-malli oli molemmilla alueilla lopulta myös hieman tarkempi kuin k-MSN-menetelmä. Molemmilla alueilla LR-malliin lisätty harhankorjaustermi lisäsi ennusteiden yliarvioita eli heikensi tarkkuutta entisestään. Kolilla menetelmien välillä oli jo siis varsin selvä tarkkuusero: k-MSN 40,18 % vs. LR-malli 34,39 %. Lineaarinen regressiomalli siis toimi itse asiassa tarkemmin Kolilla kuin Kiihtelysvaarassa. Lopullisten ennusteiden RMSE oli siis vähimmillään n. 35 % molemmilla

alueilla, mitä ei voi pitää kovinkaan käyttökelpoisena käytännön toiminnan kannalta – tosin itse mallitusdatassakin saavutettu tarkkuus oli keho.

Teoreettisen tukkitilavuuden ennusteet heikkenivät Kiihtelysvaarassa selvästi enemmän kuin kokonaistilavuuden ennusteet: LR-mallin suhteellinen RMSE kasvoi 65 % ja k-MSN menetelmän 1. versiokin 41,9 %. Tarkkuudeltaan paremman 2. version suhteellinen RMSE kasvoi 45,1 % eli hieman enemmän. Kolilla tukkitilavuusennusteiden heikkeneminen ei puolestaan ollut kuin hieman suurempaa kokonaistilavuuden ennusteisiin verrattuna, vaikka toki itse ennusteiden tarkkuus oli selvästi heikompi. Itse asiassa teoreettinen tukkitilavuus oli ainoa tutkimuksessa käsitelty tunnus, jota koskevat ennusteet selvisivät siirrosta Kolille vähemmällä epätarkentumisella kuin siirrosta Kiihtelysvaaraan. Myös kaikki ennusteet itsessäänkin olivat Kolilla tarkkuudeltaan parempia kuin vastaavat ennusteet Kiihtelysvaarassa, mutta siitäkin huolimatta lähes 50 %:n RMSE on aivan liian epätarkka saavutus ennusteelle.

Yhteenvetona voidaan siis todeta, että LR-malli tuotti k-MSN-menetelmään verrattuna tarkempia estimaatteja Kiihtelysvaaran pituus- ja tukkitilavuusennustetta sekä Kolin latvusrajaennustetta lukuun ottamatta. Muutosprosentista voidaan kuitenkin huomata vielä selkeämpi, mutta päinvastainen ero menetelmien välillä: LR-mallin suhteellinen epätarkentuminen oli k-MSN-menetelmään verrattuna vähäisempää ainoastaan Kiihtelysvaaran latvusrajaennusteen tapauksessa. Tässä tutkimuksessa k-MSN-menetelmä selvisi siis siirroista keskimäärin suhteellisesti vähäisemmällä epätarkentumisella kuin lineaariset regressiomallit.

4.3 Ennusteiden harhaisuus siirtojen jälkeen

Varsin monessa tapauksessa ennusteet olivat lopulta Kiihtelysvaarassa aliarvioita, ja Kolilla puolestaan yliarvioita. Esimerkiksi pituutta ennustavassa regressiomallissa harha oli Kiihtelysvaarassa - 3,87 % ja Kolilla 2,35 %. Purettaessa mallin yhtälö (kaava 7) pienempiin osiin, huomataan sen kaikilla tekijöillä olevan positiivinen, pituusennusteen summaa korottava vaikutus. Lopputuloksen kannalta selvästi suurin painoarvo on tekijällä H95TH_f, jonka alueellinen keskiarvo oli Liperissä 19,7 m, Kiihtelysvaarassa 17,3 m ja Kolilla 18,9 m. Näissä arvoissa on kuitenkin keskipituuksiin nähden (taulukko 2, s. 28) jo melko selvä ero: vaikuttaisi siis, että Kiihtelysvaarassa latvukseen osuneiden ensimmäisten kaikujen korkeuksien 95. persentiili määrittyy puun pituuteen nähden alemmaksi kuin Liperissä, ja Kolilla päinvastoin ylemmäksi. Kyseinen korkeuden 95. persentiili kertoo siis korkeuden, jonka alapuolella 95 % polygonin

kaiuista sijaitsee, joten Kiihtelysvaarassa pulssit ovat siis uponneet keskimäärin syvemmälle latvuksiin ennen ensimmäisen paluukaiun syntymistä.

Täysin vastaavasti myös mm. latvusrajan LR-mallilla (kaava 8) tuotetut ennusteet tuottivat Kiihtelysvaarassa aliarviota (harha - 4,91 %) ja Kolilla yliarviota (7,61 %). Kyseisessä yhtälössä suurin vaikutus on ensimmäisten kaikujen korkeuksien mediaanilla eli kaikkien havaintojen ”keskimmäisen” havainnon arvolla, joka jälleen vaihteli paljon alueellisesti: Liperi 17,1 m, Kiihtelysvaara 14,6 m ja Koli 16,1 m. Lähtökohtaisestihan mediaani ei sinänsä kerro paljoakaan jakaumasta, ellei jakauman muotoa tunneta tai voida ennalta olettaa tietynlaiseksi. Tässä tapauksessa voitaneen kuitenkin olettaa, että alhaisempi mediaani puun pituuteen suhteutettuna tarkoittaa jälleen pulssien uponneen keskimäärin syvemmälle latvukseen ennen heijastumistaan.

Syy molempiin edellä mainittuihin tapauksiin löytyy siis latvuksen rakenteista ja/tai käytetyistä keilain & parametri –yhdistelmistä. Toki on mahdollista, että Kiihtelysvaarassa järjestelmällisesti pätee, että mäntyjen latvukset eivät ole niin tuuheita tai että ne ovat terävälataisempia kuin Liperissä ja siten pulssit tunkeutuivat keskimäärin syvemmälle latvukseen (ja Kolilla päinvastoin), mutta todennäköisempi selitys ilmiölle löytynee käytetyistä keilaimista ja parametreista. Allekirjoittanut oli nimittäin itse mittaamassa jokaista mallitusdatan mäntyä, ja voi todeta aineiston sisältäneen kattavasti hyvinkin erilaisia puuyksilöitä, niin latvusrakenteiden kuin runkomuotojensakin suhteen. Puiden latvustojen rakenteellinen vaikutus ei siis kuitenkaan ole täysin poissuljettu, ja sillä voi hyvinkin olla pieni osavaikutuksensa ilmiöön.

Vastaava jakautuminen harhoissa havaittiin myös k-MSN-menetelmän 1. version pituusmallissa sekä 2. version läpimitta-, pituus- ja latvusrajamalleissa. Kahden intensiteettitunnuksen lisäämisellä selittäjäjoukkoon oli siis iso merkitys läpimitta- ja latvusrajamallien harhoihin. Erityisesti tämä näkyi läpimitan tapauksessa, sillä siinä kahden intensiteettitunnuksen sisällyttämisen seurauksena ennusteiden harha muuttui Kolilla -1,7 %:sta 1,89 %:iin. Kiihtelysvaarassa vastaava muutos oli arvosta -1,56 % arvoon -0,7 %. Erityisesti Kolilla havaittu ilmiö kertoo siitä, että intensiteettien mukaan ottamisen myötä myös kohdepuiden referenssipuut vaihtuivat suuressa määrin, mikä edelleen vahvisti sitä, että korkeus- ja intensiteettitunnusten välinen korrelaatio oli erilaista Liperissä ja Kolilla. Koska kyseessä oli kuitenkin ns. suhteellisia intensiteettitunnuksia, ei niiden vaikutus ollut kovinkaan suuri. Mutta havainto kuitenkin teki entistäkin selvemmäksi sen, että eri aineistojen intensiteetit todennäköisesti poikkeavat toisistaan huomattavasti, varsinkin jos niitä ei mitenkään normalisoida ennen käyttöä.

4.4 Syyt alueellisille eroille ennusteiden heikkenemisissä

Teoreettinen tukkitilavuus oli siis ainoa puustotunnus, jonka ennustaminen molemmilla menetelmillä onnistui tarkemmin Kolilla kuin Kiihtelysvaarassa. Lisäksi LR-mallinnettu kokonais-tilavuusennuste oli Kolilla hieman tarkempi. Vastaavasti siis myös menetelmien prosentuaaliset tunnuskohtaiset epätarkentumiset olivat Kiihtelysvaarassa vähäisempiä em. puustotunnusten tapauksia lukuun ottamatta. Tästä voidaan päätellä, että Liperin ja Kiihtelysvaaran aineistot vastasivat enemmän toisiaan, kuin Liperin ja Kolin aineistot. Ja koska lähestymistapana oli pelkkiin mäntyihin kohdistuva yksinpuintulkinta, voitaneen edelleen olettaa, että ratkaisevin tekijä oli laserkeilauksen yksityiskohtien samankaltaisuus, mikä sekin varsinkin saavutetun pistetiheyden kannalta piti paikkansa: Liperissä pistetiheys oli keskimäärin 13,2 ja Kiihtelysvaarassa vastaavasti keskimäärin 14,7 pulssia/m² (taulukko 1). Kolilla pistetiheys oli puolestaan huomattavasti heikompi, 5,2 pulssia/m², eli pistetiheys näyttäisi olevan yhteydessä tuotettujen ennusteiden tarkkuuteen sekä siirron yhteydessä tapahtuneeseen epätarkentumiseen. Yksinpuintasolla suuremmasta pistetiheydestä luonnollisesti seuraa se, että jokaiseen segmentoitavaan latvukseen osuu enemmän pulsseja, ts. latvuksen muoto ja rakenne saadaan yksityiskohtaisemmin selville, mikä taas johtaa vahvempaan kaiuista laskettavien tunnusten ja puustotunnusten väliseen korrelaatioon. Eri alueilla ensimmäisiä pulsseja/latvus olikin keskimäärin Liperissä 251, Kiihtelysvaarassa 283 ja Kolilla 149 kappaletta.

Erityisesti läpimitan ja latvusrajan ennusteet heikkenivät selvästi enemmän siirrossa Kolille kuin Kiihtelysvaaraan. Koska erot olivat selviä niin LR-mallin kuin eri k-MSN versioidenkin tapauksissa, voidaan suoraan päätellä, että Kolilla tuotettujen keilaustunnusten korrelaatio todellisiin puustotunnuksiin poikkesi huomattavasti Liperiin ja Kiihtelysvaaraan verrattuna – aivan kuten harhojen tarkastelun yhteydessä jo osittain todettiin. Tätä tukee myös se, että tutkimuspuiden keskiläpimitassa ja keskimääräisessä latvusrajassa ei ollut suuria alueellisia eroja: Liperissä keskiläpimita oli 24,8 cm, Kiihtelysvaarassa 23,1 cm ja Kolilla 24,6 cm - keskiläpimita oli siis Kolilla lähempänä mallitusaineistoa kuin Kiihtelysvaarassa. Keskimääräisessä latvusrajassakin oli Kiihtelysvaaran ja Kolin välillä vain 0,2 metrin ero. Tunnusten keskihajonnoissakaan ei ollut juuri lainkaan alueellisia eroja, tosin yksinpuintasollahan poikkeavilla keskihajonnoilla ei juurikaan ole merkitystä, kunhan käytettävä mallitusaineisto kattaa kaiken vaihtelun, kuten tässä tutkimuksessa.

5 JOHTOPÄÄTÖKSET

ALS-pohjaisten puustoennusteiden heikkeneminen vaikuttaisi siis olevan väistämätöntä myös yksinpuintasolla, kun ennusteita tuottavia malleja ja menetelmiä siirretään aineistosta toiseen. Siirron vaikutus ennusteiden tarkkuuteen ei kuitenkaan välttämättä ole suuri, mikäli käytettävät aineistot ovat toistensa kaltaisia ja tarkastelu kohdistetaan yhteen tiettyyn puulajiin. Jos siis kuviteltaisiin skenaario, jossa tuotettaisiin tiheäpulssinen keilausaineisto mäntyleimikoiden laadun arvioimiseksi, edellytettäisiin maastotöiden vähentämiseksi sitä, että keilaus suoritetaan mahdollisimman vastaavilla keilausparametreilla, kuin mitä on käytetty jo olemassa olevaa mallitusaineistoa keilatessa. Käytettävässä mallitusaineistossa saavutettujen ennustetarkkuuksien tulisi ehdottomasti kuitenkin olla ainakin kokonais- ja tukkilavuuden osalta parempia kuin tässä tutkimuksessa, sillä eri puutavaralajien kertymät ovat erittäin oleellinen osa hakkuiden suunnittelussa ja ne tulisi kyetä ennustamaan mahdollisimman tarkasti. Esim. vastaavilla tarkkuuksilla kuin mitä Maltamon ym. (2009b) tutkimuksessa saavutettiin, voitaisiin myös kohdealueilla päästä riittävän hyviin tarkkuuksiin. Mänty on lisäksi puulajina varsin säännöllinen sekä latvukseltaan että runkomuodoltaan, joten mallit todennäköisesti olisivat maantieteellisesti siirrettävissä ainakin muutamia satoja kilometrejä ilman puuston vaihtelun aiheuttamaa suurta heikkenemistä, edelleen kuitenkin edellyttäen, että referenssiaineisto kattaa mäntyjen keskinäisen vaihtelun.

Tässä tutkimuksessa eri alueiden keilaukset poikkesivat toisistaan huomattavasti, mikä erittäin todennäköisesti johti myös tuotettujen kaikutunnusten erilaisuuksiin: ALS-tunnusten jakaumat ja edelleen niiden avulla tuotetut ennusteet olisivat siis todennäköisesti poikenneet toisistaan, vaikka käytetyillä eri keilain & parametri -yhdistelmillä olisi keilattu sama alue. ALS-mallien siirrettävyyden tarkemmassa tutkimisessa olisikin syytä kaventaa virhelähteet koskemaan keilauksesta tai puustosta vain jompaakumpaa, joko keilaamalla sama puusto monella keilain & parametri -yhdistelmällä, kuten mm. Keränen ym. (2016) (keilaimen/parametrien vaikutus) tai keilaamalla eri alueet samalla keilaimella ja parametreilla (puuston vaikutus). ITD-lähestymistavan tapauksessa keilausaineistolta edellytetään kuitenkin korkeaa pistetiheyttä ja toisaalta myös puiden sijaintitietoa, eli esimerkiksi Metsäkeskuksen olemassa olevat harva-pulssiset ABA-menetelmää varten kerätyt aineistot eivät ole käyttökelpoisia, vaikka ne pinta-alalliselta laajuudeltaan voisivatkin jo mahdollistaa siirrettävyyden tutkimisen. Käytännössä yksinpuintulkinnan siirrettävyyden tutkimiseksi kaikki työvaiheet olisi siis tehtävä täysin alusta alkaen, eli toteutuksen kustannukset nousisivat korkealle.

Aihetta olisi kuitenkin syytä tutkia vielä lisää. Toki yksinpuintason puustotulkinnan tulisi ylipäätään olla operatiivisessa käytössä, jotta mallien siirrettävyydestä seuraisi myös konkreettista hyötyä alhaisempien maastotyökustannusten muodossa. Erilaiset ALS-metodit ovat kuitenkin kehittyneet nopeasti viime vuosikymmeninä, ja odotettavissa on, että mm. tarkentuvien aineistojen myötä kehitystä tapahtuu myös jatkossa. Tulevaisuudessa ITD-mallien siirrettävyyden ja siihen vaikuttavien seikkojen sekä esim. mallien kalibrointimahdollisuuksien tunteminen voikin osoittautua erittäin merkittäväksi ja hyödylliseksi tiedoksi. Kenties voisi esimerkiksi olla mahdollista luoda alueellisia ”mäntytielopankkeja”, joista vaikkapa juuri lähimmän naapurin menetelmällä voitaisiin sitten suoraan ennustaa laatutunnuksia jopa satojen kilometrien päässä täysin erillisillä inventointialueilla sijaitseville männyille?

KIRJALLISUUS

- Bollandsås, O.M., Maltamo, M., Gobakken, T., Lien, V. & Næsset, E. 2011. Prediction of Timber Quality Parameters of Forest Stands by Means of Small Footprint Airborne Laser Scanner Data. *International Journal of Forest Engineering* 22(1): 14-23.
- Gobakken, T. & Næsset, E. 2009. Assessing effects of positioning errors and sample plot size on biophysical stand properties derived from airborne laser scanner data. *Canadian Journal of Forest Research* 39: 1036-1052.
- Gopalakrishnan, R., Thomas, V., Coulston, J.W. & Wynne, R. 2015. Prediction of Canopy Heights over a Large Region Using Heterogeneous Lidar Datasets: Efficacy and Challenges. *Remote Sensing* 7: 11036-11060; doi:10.3390/rs70911036
- Holopainen, M., Vastaranta, M., Rasinmäki, J., Kalliovirta, J., Mäkinen, A., Haapanen, R. Melkas, T., Yu, X. & Hyyppä, J. 2010. Uncertainty in timber assortment estimates predicted from forest inventory data. *European Journal of Forest Research* 129: 1131–1142.
- Holopainen, M., Hyyppä, J. & Vastaranta, M. 2013. Laserkeilaus metsävarojen hallinnassa. *Helsingin yliopiston metsätieteiden laitoksen julkaisuja* 5: 1–75.
- Hyyppä, J., Kelle, O., Lehikoinen, M. & Inkinen M. 2001. A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. *IEEE Transactions on Geoscience and Remote Sensing* 39(5): 969–975.
- Hyyppä, J., Holopainen, M. & Olsson, H. 2012. Laser Scanning in Forests. *Remote Sensing* 4: 2919-2922; doi:10.3390/rs4102919
- Kalliovirta, J. & Tokola, T. 2005. Functions for estimating stem diameter and tree age using tree height, crown width and existing stand database information. *Silva Fennica* 39(2): 227–248.

- Keränen, J., Maltamo, M. & Packalén, P. 2016. Effect of flying altitude, scanning angle and scanning mode on the accuracy of ALS based forest inventory. *International Journal of Applied Earth Observation and Geoinformation* 52: 349-360. <http://dx.doi.org/10.1016/j.jag.2016.07.005>
- Khosravipour, A., Skidmore, A.K., Isenburg, M., Wang, T.J. & Hussin, Y.A. 2014. Generating pit-free Canopy Height Models from Airborne LiDAR. *Photogrammetric Engineering and Remote Sensing* 80: 863-872.
- Korhonen, L., Peuhkurinen, J., Malinen, J., Suvanto, A., Maltamo, M., Packalen, P. & Kangas, J. 2008. The use of airborne laser scanning to estimate sawlog volumes. *Forestry* 81(4): 499–510.
- Korpela, I., Tuomola, T. & Välimäki, E. 2007. Mapping forest plots: an efficient method combining photogrammetry and field triangulation. *Silva Fennica* 41: 457–469.
- Korpela, I., Ørka, H. O., Maltamo, M., Tokola, T. & Hyypä, J. 2010. Tree species classification using airborne LiDAR – effects of stand and tree parameters, downsizing of training set, intensity normalization and sensor type. *Silva Fennica* 44: 319-339.
- Kotivuori E., Korhonen L. & Packalen P. 2016. Nationwide airborne laser scanning based models for volume, biomass and dominant height in Finland. *Silva Fennica* 50(4): 1-28; <http://dx.doi.org/10.14214/sf.1567>.
- Laasasenaho, J. 1982. Taper curve and volume function for pine, spruce and birch. *Communications Instituti Forestalis Fenniae* 108: 1-74.
- Maltamo, M., Packalén, P., Suvanto, A., Korhonen, K.T., Mehtätalo, L. & Hyvönen, P. 2009a. Combining ALS and NFI training data for forest management planning: a case study in Kuortane, Western Finland. *European Journal of Forest Research* 128: 305-317.
- Maltamo, M., Peuhkurinen, J., Malinen, J., Vauhkonen, J., Packalén, P. & Tokola, T. 2009b. Predicting tree attributes and quality characteristics of Scots pine using airborne laser scanning data. *Silva Fennica* 43(3): 507-521.
- Maltamo, M., Bollandsås, O.M., Vauhkonen, J., Breidenbach, J., Gobakken, T. & Næsset, E. 2010. Comparing different methods for prediction of mean crown height in Norway spruce stands using airborne laser scanner data. *Forestry* 83: 257–268; <https://doi.org/10.1093/forestry/cpq008>
- Maltamo, M., Mehtätalo, L., Vauhkonen, J. & Packalén, P. 2012. Predicting and calibrating tree size and quality attributes by means of airborne laser scanning and field measurements. *Canadian Journal of Forest Research* 42: 1896–1907.
- Mehtätalo, L. 2002. Valtakunnalliset puukohtaiset tukkivähennysmallit männyille, kuuselle, koivuille ja haavalle. *Metsätieteen aikakauskirja* 2002(4): 575–591.
- Næsset, E., 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment* 80: 88–99.
- Næsset, E. & Økland, T. 2002. Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. *Remote Sensing of Environment* 79: 105-115.
- Næsset, E. 2004. Practical Large-scale forest stand inventory using a small-footprint airborne scanning laser. *Scandinavian Journal of Forest Research* 19: 164–179.

- Næsset, E. 2008. Effects of different sensors, flying altitudes, and pulse repetition frequencies on forest canopy metrics and biophysical stand properties derived from small-footprint airborne laser data. *Remote Sensing of Environment* 113: 148-159; doi:10.1016/j.rse.2008.09.001
- Nilsson, M., Nordkvist, K., Jonzén, J. Lindgren, N., Axensten, P., Wallerman, J., Egberth, M., Larsson S., Nilsson, L., Eriksson, J. & Olsson, H. 2016. A nationwide forest attribute map of Sweden predicted using airborne laser scanning data and field data from the National Forest Inventory. *Remote Sensing of Environment* 194: 447-454; dx.doi.org/10.1016/j.rse.2016.10.022
- Packalén, P. & Maltamo, M. 2007. The k-MSN method in the prediction of species specific stand attributes using airborne laser scanning and aerial photographs. *Remote Sensing of Environment* 109: 328–341.
- Persson, Å., Holmgren, J. & Söderman, U. 2002. Detecting and measuring individual trees using an airborne laser scanner. *Photogrammetric Engineering & Remote Sensing* 68: 925–932.
- Peuhkurinen, J., Maltamo, M., Malinen, J., Pitkänen, J. & Packalén, P. 2007. Preharvest measurement of marked stands using airborne laser scanning. *Forest Science*. 53(6): 653– 661.
- Peuhkurinen, J., Maltamo M. & Malinen, J. 2008. Estimating species-specific diameter, distributions and saw log recoveries of boreal forests from airborne laser scanning data and aerial photographs: a distribution-based approach. *Silva Fennica* 42: 625–641.
- Repola, J. 2009. Biomass equations for Scots pine and Norway spruce in Finland. *Silva Fennica* 43(4): 625-647.
- Silva, C., Crookston, N., Hudak, A., Vierling, L., Klauberg, C. & Cardil, A. 2017. rLiDAR: LiDAR Data Processing and Visualization. R package version 0.1.1. <https://CRAN.R-project.org/package=rLiDAR>
- Suvanto, A., Maltamo, M., Packalén, P. & Kangas, J. 2005. Kuviokohtaisten puustotunnusten ennustaminen laserkeilauksella. *Metsätieteen aikakauskirja* 2005(4): 413–428.
- Utterä, J., Anttila, P., Suvanto, A. & Maltamo, M. 2006. Yksityismetsien metsävaratiedon keruuseen soveltuvilla kaukokartoitusmenetelmillä estimoitujen puustotunnusten luotettavuus. *Metsätieteen aikakauskirja* 2006(4): 507-519.
- Vauhkonen, J. 2010. Estimating crown base height for Scots pine by means of the 3D geometry of airborne laser scanning data. *International Journal of Remote Sensing* 31(5): 1213-1226; DOI: 10.1080/01431160903380615
- Vauhkonen, J., Korpela, I., Maltamo, M. & Tokola, T. 2010. Imputation of single-tree attributes using airborne laser scanning-based height, intensity, and alpha shape metrics. *Remote Sensing of Environment* 114: 1263-1276.
- Villikka, M., Maltamo, M., Packalén, P., Vehmas, M., & Hyyppä, J. 2007. Alternatives for predicting tree-level stem volume of Norway spruce using airborne laser scanner data. *The Photogrammetric Journal of Finland* 20(2): 33–42.
- Wallace, L., Lucieer, A., Malenovský, Z., Turner, D. & Vopěnka, P. 2016. Assessment of Forest Structure Using Two UAV Techniques: A Comparison of Airborne Laser Scanning and Structure from Motion (SfM) Point Clouds. *Forests* 7(3): 1-62; doi:10.3390/f7030062

Yu, X., Hyyppä, J., Hyyppä, H. & Maltamo, M. 2004. Effects of flight altitude on tree height estimation using airborne laser scanning. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36(8/W2): 96–101.

LIITTEET

k-MSN-menetelmä

Liite 1

Kanonisten korrelaatioiden avulla on mahdollista löytää lineaariset muunnokset U_k ja V_k , jotka maksimoivat niiden keskinäisen korrelaation (kaava 12).

$$U_k = \alpha_k Y \quad \& \quad V_k = \gamma_k X \quad \text{(kaava 12)}$$

jossa

Y = puun tunnuksset (esim. läpimitta)

X = ALS-tunnuksset

α_k = selittävien tekijöiden kanoninen kerroin

γ_k = selitettävien tekijöiden kanoninen kerroin

Kanonisesta korrelaatiosta johdettu MSN-etäisyysfunktio (kaava 13):

$$D_{uj}^2 = \begin{matrix} (X_u - X_j) & \Gamma \Lambda^2 \Gamma' & (X_u - X_j)' \\ 1xp & pxp & px1 \end{matrix} \quad \text{(kaava 13)}$$

jossa

X_u = vektori kohdehavainnon tunnetuista hakumuuttujista

X_j = vektori referenssihavainnon tunnetuista hakumuuttujista


Γ = matriisi ennustavien muuttujien kanonisista kertoimista

Λ = diagonaalinen matriisi neliöidyistä kanonisista korrelaatioista


Taulukko 15. Tutkimuksesta hylätyn 5 korkeus- ja 5 intensiteettitunnusta sisältäneen k-MSN version tuottamat ennustetarkkuudet. Käytetyt intensiteettitunnukset: ensimmäisten kaikujen intensiteettijakauman vinous, ensimmäisten kaikujen puutason intensiteettien 10. persentiili, viimeisten kaikujen puutason intensiteettien 30. persentiili, viimeisten kaikujen intensiteetin puutason maksimi sekä koalatason intensiteettien 50. persentiili. Korkeustunnukset olivat samat kuin tutkimuksessa käytetyissäkin versioissa.

		Liperi	Kiihtelysvaara	Koli
Läpimitta	RMSE (cm)	3.02	6.32	6.08
	%-RMSE	12.17	27.39	24.73
	HARHA (cm)	-0.01	4.68	4.04
	%-HARHA	-0.02	20.29	16.45
Pituus	RMSE (m)	0.70	2.43	2.01
	%-RMSE	3.31	12.45	10.08
	HARHA (m)	-0.02	-0.05	0.06
	%-HARHA	-0.08	-0.25	0.29
Latvusraja	RMSE (m)	1.79	2.20	2.45
	%-RMSE	13.49	19.89	21.82
	HARHA (m)	-0.03	0.90	0.89
	%-HARHA	-0.21	8.15	7.96
Kokonaistilavuus	RMSE (l)	134.44	282.60	253.99
	%-RMSE	26.51	75.30	53.76
	HARHA (l)	-1.15	198.19	158.22
	%-HARHA	-0.23	52.81	33.49
Tukkitilavuus	RMSE (l)	145.21	311.83	273.33
	%-RMSE	34.68	112.73	70.73
	HARHA (l)	-0.89	221.90	171.65
	%-HARHA	-0.21	80.22	44.42

Läpimitta:




Kuva 25. k-MSN-ennusteen hajontakuvaaja läpimitan suhteen (versio 1).




Kuva 26. k-MSN-ennusteen jäännöskuvaaja läpimitan suhteen (versio 1).

Pituus:




Kuva 27. k-MSN-ennusteen hajontakuvaaja pituuden suhteen (versio 1).




Kuva 28. k-MSN-ennusteen jäännöskuvaaja pituuden suhteen (versio 1).

Latvusraja:




Kuva 29. k-MSN-ennusteen hajontakuvaaja latvusrajan suhteen (versio 1).




Kuva 30. k-MSN-ennusteen jäännöskuvaaja latvusrajan suhteen (versio 1).

Kokonaistilavuus:

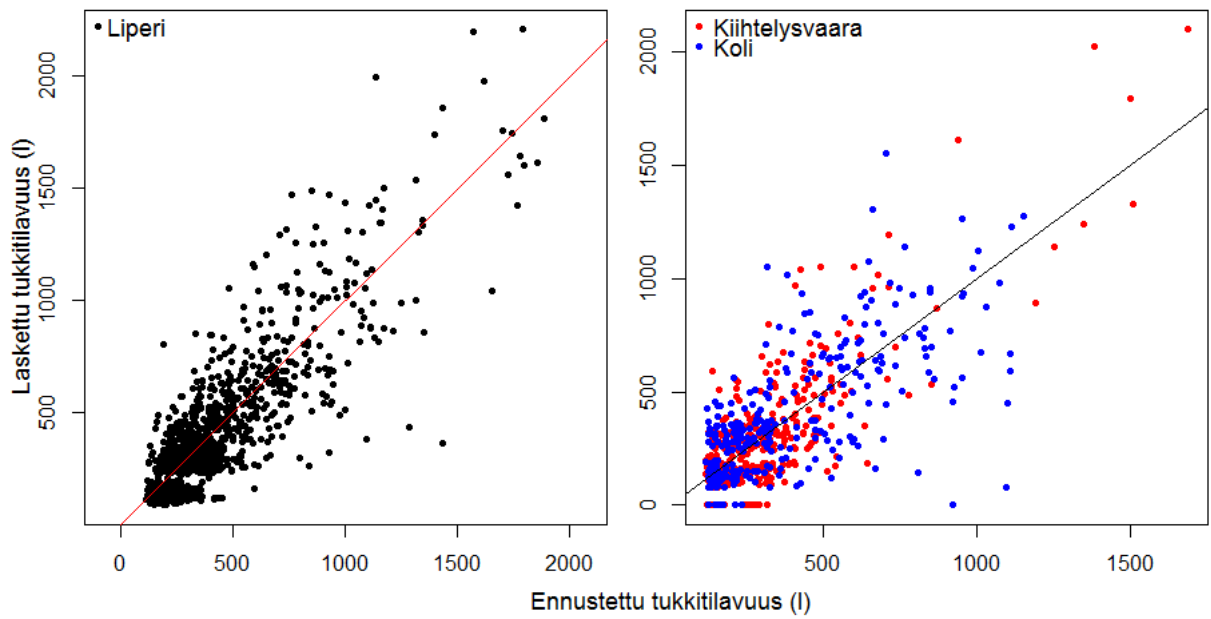


Kuva 31. k-MSN-ennusteen hajontakuvaaja kokonaistilavuuden suhteen (versio 1).




Kuva 32. k-MSN-ennusteen jäännöskuvaaja kokonaistilavuuden suhteen (versio 1).

Tukkitilavuus:



Kuva 33. k-MSN-ennusteen hajontakuvaaja tukkitilavuuden suhteen (versio 1).



Kuva 34. k-MSN-ennusteen jäännöskuvaaja tukkitilavuuden suhteen (versio 1).