

KARELIA-AMMATTIKORKEAKOULU

Metsätalouden koulutusohjelma

Alain Minguet

VANHAN KUVIOTIETOAINIESTON KÄYTTÖ LASERKEILAUS-
PERUSTEISEN METSIEN INVENTOINNIN APUTIETOLÄHTEENÄ

Opinnäytetyö

Tammikuu 2013



OPINNÄYTETYÖ
Tammikuu 2013
Metsätalouden koulutusohjelma

Sirkkalantie 12A
80100 JOENSUU
013 260 6900

Tekijä(t)
Alain Minguet

Nimeke
Vanhan kuviotietoaineiston käyttö laserkeilausperusteisen metsien inventoinnin aputietolähteenä
Toimeksiantaja
Oy Arbonaut Ltd

Tiivistelmä

Laserkeilaukseen perustuva metsäinventointi on yleistymässä Suomessa. Tulosten luotettavuus on saavuttanut hyvän tason, ja kokonaispuuston tunnusten ennustamisessa tulokset ovat parempia kuin perinteisessä kuvioittaisessa arvioinnissa. Puulajikohtaiset ennusteet eivät ole olleet yhtä luotettavia.

Tässä tutkimuksessa testattiin, paraneeko puuston iän ja puulajisuhteiden ennustamisen tarkkuus, kun mallinnukseen lisätään asiakkaan tietokannasta saatua olemassa olevaa kuviokohtaista aineistoa. Ennustamisessa käytettiin lisäksi harvapulssista laserkeilausaineistoa, ilmakuvia ja maastokoealoja. Estimointi tehtiin harva bayesilainen -menetelmällä.

Toimeksiantaja Arbonaut Oy on erikoistunut luonnonvarojen kaukokartoitukseen ja erityisesti laserkeilausaineiston tulkintaan. Tutkimuksessa käytettiin yrityksen toiminnassa hyödynnettyä yli 500:aa koalaa noin 220 000 hehtaarin kokoiselta, Metsähallituksen mailla sijaitseva alueelta.

Tulokset olivat hyviä. Ennusteiden luotettavuus parani keskimäärin noin 1,5 %. Erityisesti kuusen ja männyn osalta ennuste parani merkittävästi. Iän ennustaminen parani 4,65–7,37 prosenttiyksikköä.

Kieli
suomi

Sivuja 35

Asiasanat
LiDAR, laserkeilaus, metsäinventointi



THESIS
January 2013
Degree Programme in Forestry
Sirkkalantie 12A
FI 80100 JOENSUU
FINLAND
+358 132606900

Author(s)
Alain Minguet

Title
Using of Old Forest Stand Database as Secondary Data Source in Airborne Laser Scanning-Based Forest Inventory
Commissioned by
Oy Arbonaut Ltd

Abstract

Airborne laser scanning (ALS)-based forest inventory is becoming more and more common in Finland. The reliability of the results has reached a good level, and the predictions for the parameters of total growing stock are often better than in traditional compartmental assessment. Species-specific tree estimates are not equally reliable.

This study tested if the tree stand age and tree species composition prediction accuracy improves, when stand-specific material from an existing customer database is added to the model. In addition, low-density ALS, aerial photos and field plot observations were used for the prediction. The estimation was done with the sparse Bayesian method.

This work was commissioned by Arbonaut Ltd, which company is specialized in remote sensing of natural resources and, in particular, in interpretation of ALS. The study utilized over 500 trial plots in an area of about 220 000 hectares owned by Metsähallitus and used in the company's operations.

The results were good. The reliability of estimates improved, on average, by about 1.5 percent. In particular, the predictions for spruce and pine improved significantly. Age prediction improved by 4.65 - 7.37 percent.

Language
Finnish

Pages 35

Keywords
LiDAR, airborne laser scanning, ALS, forest inventory

Sisältö

1	Johdanto	5
2	Laserkeilaukseen perustuva metsäinventointi.....	6
2.1	Kaukokartoitus metsäinventoinnissa.....	6
2.2	Laserkeilauksen toimintaperiaate.....	6
2.3	Tarkkuus eri metsäinventoinnin menetelmissä	8
2.4	Puuston iän ja puulajisuhteen ennustaminen.....	10
3	Opinnäytetyön tausta ja tavoitteet.....	11
3.1	Toimeksiantaja	11
3.2	Opinnäytetyön tavoitteet	12
4	Aineisto ja menetelmät.....	12
4.1	Tulkinta-alue	13
4.2	Maastokoealat	14
4.3	Kaukokartoitusaineisto.....	15
4.4	Vanha kuvioaineisto.....	15
4.5	Tilastolliset menetelmät	17
4.6	Tulosten luotettavuuden arvioinnin menetelmät.....	18
5	Tulokset ja tulosten tarkastelu.....	19
5.1	Puulajisuhde	19
5.2	Ikä.....	29
6	Päätelmät	31
	Lähteet.....	34

1 Johdanto

Laserkeilauksen, jossa kerätään ilmasta käsin pistemäistä LiDAR-aineistoa, on esitetty useissa tutkimuksissa (esim. Suvanto, Maltamo, Packalén, & Kangas, 2005; Packalén, 2009; Uuttera, Anttila, Suvanto, & Maltamo 2006) olevan vähintäänkin varteenotettava vaihtoehto verrattuna nykyisiin menetelmiin, esimerkiksi SOLMU-menetelmään, metsäinventoinnissa. Nykyiset mittausmenetelmät kuvioittaisessa metsäinventoinnissa ovat suhteellisen kalliita, hitaita ja epätarkkoja.

Puustotunnusten estimointi LiDAR-aineiston ja ilmakuvien perusteella on laajasti tutkittu. Menetelmällä on päästy hyviin tuloksiin, jotka ovat jopa parempia kuin tavallisessa metsäinventoinnissa muun muassa tilavuuden, keskipituuden ja pohjapinta-alan osalta. Puustotunnusten ennustaminen puulajeittain on enemmän huomioitu viime vuosien tutkimuksissa, mutta tulokset eivät ole yhtä tarkkoja kuin kokonaispuuston tunnusten estimoinnissa (mm. Suvanto ym. 2005, Packalén & Maltamo 2007). Puuston iän määrittäminen laserkeilausaineiston perusteella on jäänyt tutkimuksissa vähälle huomiolle.

Toimeksiantaja Arbonaut Oy on erikoistunut luonnonvarojen kaukokartoitukseen ja erityisesti laserkeilausaineiston tulkintaan. Tutkimuksessa käytettiin yrityksen toiminnassa hyödynnettyä yli 500 koealaa noin 220 000 hehtaarin kokoiselta, Metsähallituksen mailla sijaitsevalta alueelta.

Tässä tutkimuksessa testattiin Arbonaut Oy:n metsäinventoinnin tuotantoprosessissa paraneeko puuston iän ja puulajisuhteiden ennustamisen tarkkuus, kun lisätään mallinnukseen asiakkaan tietokannasta saatu vanha kuviokohtainen aineisto. Ennustamisessa käytettiin myös harvapulssista laserkeilausaineistoa, ilmakuvia ja koealojen mittaustietoa.

2 Laserkeilaukseen perustuva metsäinventointi

2.1 Kaukokartoitus metsäinventoinnissa

Kaukokartoitus on ollut käytössä Suomessa eri muodoissa yli 70 vuoden ajan apuna metsäinventoinnissa. Teknologian kehitys mahdollistaa käyttötarkoituksen muutokset aina yksittäisen puun mittauksesta laajojen alueiden tunnusten estimointiin. Kaukokartoitusaineistosta on tullut myös päätietolähde inventoinneissa. (Kangas, Päivinen, Holopainen & Maltamo 2011, 141–143.)

Ilmakuvien ja Landsat-sateliittikuvien tulkinnassa on melko pitkät perinteet, ja Suomessa onkin kehitetty kuvien sävy- ja tekstuuriarvoja hyödyntäviä tulkintamenetelmiä erityisesti VMI:n aineiston käyttäen. Saavutettu tarkkuus näissä menetelmissä ei ole kuitenkaan sellainen, jota on toivottu. (Kangas ym. 2011. 142–144.)

LiDAR-aineiston (Light Detection And Ranging) avulla päästetään jo vähintään yhtä tarkkoihin kuvioittaisiin tuloksiin kuin tavallisessa metsäinventoinnissa. Laserkeilaukseen (myös ALS, Airborne Laser Scanning) perustuva metsäinventointi on varsin paljon tutkittu reilun 15 vuoden aikana. (Kangas ym. 2011. 144–145; Næsset 2002.)

Lisäämällä kaukokartoitusaineistoa metsäinventointiin haetaan kustannustehokkaampia menetelmiä. Maastoinventoinnin kustannukset ovat keskimäärin 9,2 €/ha koko inventointiprosessin maksaessa 17,3 €/ha. Harvapulssista laserkeilausaineistoa voidaan saada alle 1 € hehtaarihinnalla suurille alueille, kun ilmakehän aineisto maksaa noin 0,1 €/ha. (Uuttera ym. 2006, 508, 516–517; Hyvönen 2007, 9.)

2.2 Laserkeilauksen toimintaperiaate

Laserkeilain lähettää tiheästi ja automaattisesti laserpulsseja, jotka heijastuvat takaisin yhtenä tai useampana paluukaikuna osumapinnan läpäisevyydestä riippuen. Pulsstit eivät kuitenkaan läpäise kovia pintoja käytetyn aallonpituuden takia, vaan useampia pulsseja

saadaan sieltä, mistä valokin pääsee esimerkiksi latvusten läpi. Mittaamalla aikaväli pulssin lähettämisen ja paluukaiun välillä voidaan laskea heijastuneen pulssin etäisyys keilaimesta ja edelleen sen tarkka korkeus eli sijainti Z-koordinaatistossa. Voidaan olettaa, että ensimmäiset kaiut kuvaavat latvustoa ja suurin osa viimeisistä kaiuista maaston korkeutta. Laserkeilaimen tarkka sijainti, eli X ja Y-koordinaatit, on tiedossa lentokoneessa olevan GPS (Global Positioning System) ja lentonavigoinnin järjestelmän (INS inertial navigation system) avulla. Kun jokaisen laserpisteen XYZ-koordinaatit tiedetään, saadaan kokonaisaineistosta ns. kolmeulotteinen pistepilvi, jotka käytetään metsikkötunnusten laskemiseen. (Aronoff & Petrie 2005, 229–233, 238; Packalén, 2009, 9–10.)

Laserkeilauksen vertikaalinen mittaustarkkuus on 15–50 cm maastonmuodoista, ilma-alueksen lentokorkeudesta (yleensä 200–3000 m), laitteesta ja pisteiden tunnusten laskemisen laadusta (kuten maanpinnan mallinnus) riippuen. Tarkempia mittauksia (5 cm:n tarkkuus) voidaan saavuttaa lentämällä helikopterilla alle 100 metrin korkeudella. (Aronoff & Petrie 2005, 231; Packalén, 2009, 11.)

Metsäinventoinnissa voidaan käyttää tiheäpulsseista laserkeilainaineistoa (3–10 pulssia/m²), joka on yksinpuintulkintaan vaadittava tiheys, tai harvapulsseista aineistoa (0,1–1 pulssia/m²), jossa lasketaan metsikkökohtaisia tunnuksia latvuston korkeusjakaumaa hyödyntäen. (Hyvönen 2007, 12–13; Aronoff & Petrie 2005, 230–231.)

Suomessa metsäinventoinnissa käytetään yleensä lentokoneesta keilattua harvapulssiaineistoa kustannustehokkuuden takia. Tiheäpulsssiaineiston mahdollistama yksinpuintulkinta on haasteellista tiheässä metsässä, joissa alikasvosta ei pystytä laserkeilaimella havaitsemaan. Harvapulsseiseen laserkeilainaineistoon perustuvat inventointimenetelmät vievät vähemmän aikaa kuin yksinpuinmenetelmässä, sillä viimeisessä algoritmit on säädettävä metsikkökohtaisesti. (Packalén 2009, 10–11; Uuttera ym. 2006, 517.)

Tulevaisuudessa yksinpuintulkintaan perustuvat menetelmät voisivat kuitenkin olla hyödyllisiä, jotta saataisiin tarkempaa tietoa puulajista, puutavaralajijakaumasta tai

puuston laadusta. Yksinpuintulkinta on paljon tutkittu viime kymmenen vuoden aikana. (Uuttera ym. 2006, 516; Peuhkurinen 2011, 10.)

LiDAR-muuttujat on laskettu Junttila ym. (2010, 266) tutkimuksen perusteella. 38 muuttujasta kahdeksaa ei yleensä käytetä Arbonaut Oy:n tuotantoprosessissa niiden epävakauden vuoksi. Lisäksi tähän tutkimukseen ei ole otettu mukaan intensiteettimuuttujia. Käytetyt LiDAR-muuttujat on esitetty taulukossa 1.

Taulukko 1. Opinnäytetyössä käytetyt LiDAR-muuttujat.

Muuttuja	Selite
1..10	Korkeus 10%, 20%, 30% ... 100% persentilissä ensimmäisistä kaiuista.
11..20	Korkeus 10%, 20%, 30% ... 100% persentilissä viimeisistä kaiuista.
27	Ensimmäisten kaikujen keskikorkeus
28	Ensimmäisten kaikujen keskihajonta
29	Suhdeluku ensimmäisen alikasvillisuuden ensimmäisen kaiun (pisteet alle "maan_kynnysarvo" metreinä) ja kaikki ensimmäisten kaikujen välillä
30	Suhdeluku ensimmäisen alikasvillisuuden viimeisen kaiun (pisteet alle "maan_kynnysarvo" metreinä) ja kaikki viimeisten kaikujen välillä

2.3 Tarkkuus eri metsäinventoinnin menetelmissä

Metsäinventointi ei voi olla sataprosenttisen tarkkaa ja virheet on hyväksyttävä. Tulosten on kuitenkin oltava mahdollisimman hyviä. Tulosten tarkkuutta voidaan arvioida suhteellisen keskivirheen (RSME%, relavite root mean square error) avulla. Kuviotason tilavuuden tavoitetasoksi on esitetty 15–35 %, keskiläpimitalle ja pituudelle 10–25 % ja pohjapinta-alalle 15–33 % (Hyvönen 2007, 14).

Tässä opinnäytetyössä käytetyn inventointiprojektin asiakas asetti laatutavoitteet tarjouspyynnössään metsätalouden kehittämiskeskus Tapion mukaisesti. Tavoitearvot RMSE%:na on esitetty taulukossa 2. (Tarjouskilpailu.fi 2011.)

Taulukko 2. Asiakkaan tavoitteet tulosten luotettavuudelle.

muuttuja	h	d1.3	ppa	v
kok.puusto	10	15	20	20
pääpuulaji	15	20	30	40
sivupuulaji	20	30	50	60

Kuvioittaisen arvioinnin SOLMU-metsäsuunnittelujärjestelmässä kokonaistilavuuden suhteellinen RMSE on keskimäärin 24,8 % (37,5 m³/ha) ollen suurimmillaan kuusikoissa. Tarkkuus vaihtelee mm. metsikön tiheyden, puulajin tai mitaajan mukaan. Keskiläpimitan keskivirhe oli 12,6 %, keskipituuden 15,7 % ja pohjapinta-alan 19,6 %. Yksi menetelmän ongelmista on subjektivisuus suunnittelijan päättäessä muun muassa kuvioden rajoista, koelajien sijainnista ja määrästä. (Haara & Korhonen 2004, 489–491, 503–507.)

Utterera ym. (2006, 509) ovat vertailleet SOLMU-menetelmää ja neljää kaukokartoitusmenetelmää:

- 1) fotogrammetrisiin puutason mittauksiin ja visuaaliseen puulajitulkintaan perustuva ilmakuvatulkinta (*PhotoAP*),
- 2) puoliautomaattinen yksinpuintulkinta numeeriselta ilmakuvulta (*SegAP*),
- 3) puoliautomaattinen yksinpuintulkinta ilmakuvulta ja laserkeilausaineistosta (*SegALS*) ja
- 4) laserkeilainaineiston korkeusjakaumaan perustuva menetelmä (*PhdALS*).

Tutkimuksessa kävi ilmi, että neljäs menetelmä (*PhdALS*) tuottaa tarkimmat tulokset erityisesti puuston kokonaistilavuudessa (RMSE% 17,8–18,8), vaikka käytetyt mallit oli kehitetty Suvannon ym. (2005) tutkimuksessa erilaiselle aineistolle. Menetelmä tuottaa ainakin yhtä hyviä estimaatteja kuin SOLMU-menetelmä. (Utterera ym. 2006, 513–516.)

Suvanto ym. (2005, 413–424) saavuttivat paremman tarkkuuden tutkimuksessaan, jolloin RMSE oli alle 10 % keskiläpimitassa, keskipituudessa, pohjapinta-alassa ja tilavuudessa. Tulokset eri tutkimuksissa ja menetelmissä ovat tarkimmillaan varttuneimmissa ja homogeenisemmissä metsiköissä, ja puulajeittaisissa tuloksissa männyllä (Suvanto ym. 2005, 413–424; Utterera ym. 2006, 513–516).

Metsäinventoinnin tulokset ovat heikkoja, jos kaukokartoitusperusteisena lähtöaineistona on käytetty pelkästään ilmakuvaa. Laserkeilauksella saadut tulokset ovat vähentäneet kiinnostusta ilmakuvien käyttöön ilman rinnakkaisaineistoa. (Packalén 2009, 13.)

2.4 Puuston iän ja puulajisuhteen ennustaminen

Packalénin (2009, 14–15) mukaan suurin osa laserkeilausta koskevista tutkimuksista on keskittynyt kokonaispuuston tunnusten laskemiseen, muttei esimerkiksi puulajin määrittämiseen. Selityksenä voisi olla, ettei pääpuulajin estimointitulokselle ole kysyntää tai käyttöä, koska useimmiten intensiivisessä metsänhoidossa metsiköiden pääpuulaji on tiedossa, tai puulajien ennustamisen tarkkuustasoa ei pidetä riittävän hyvänä. Laserkeilausaineiston käyttö samanaikaisesti ilmakuvien kanssa on perusteltua puulajin määrittämisessä.

Puuston keskitilavuuden ennustaminen puulajeittain on osoittautunut vähemmän tarkaksi kuin esimerkiksi kokonaispuuston estimointi, erityisesti lehtipuiden osalta. Packalén & Maltamo (2006, 618) selittävät tätä sillä, että lehtipuut ovat harvoin Suomen talousmetsissä pääpuulajina, ja puulajeittainen ennustaminen onnistuu parhaiten pääpuulajille. Sellaisten koealojen määrä, jossa lehtipuu olisi pääpuulajina, on koeala-aineistossa usein sen verran pieni, että tarkka ennustaminen on vaikeata. Samasta syystä lehtipuut ovat yhdessä luokassa, eikä ole mahdollista erotella esimerkiksi koivua muista lehtipuista.

Packalén ja Maltamo (2007, 335–340) ovat saaneet kuviotason tilavuuden suhteelliseksi keskivirheeksi lehtipuulla 63,33 %, männyllä 28,08 % ja kuusella 32,64 %, kun käytössä on ollut ilmakuvia ja harvapulssista laserkeilausaineistoa. Silloin on käytetty 463 koealaa ja regressiomallia k-MSN-menetelmällä.

Iän määrittämistä ALS-aineiston perusteella ei ole kovin laajalti tutkittu. Hyvönen (2002) on tutkimuksessaan määrittänyt puuston iän ilman laserkeilausaineistoa käyttäen Landsat TM-satelliittikuvia, vanhaa inventointiaineistoa ja kuviotason tukiaineistoa tutkimuksen tarkoituksen ollessa puustotietojen ja toimenpide-ehdotusten estimointi.

Silloin suhteellinen keskivirhe puuston iän estimoinnille on ollut parhaimmillaan 34,64 % (26 % kehitysluokille 02–04).

3 Opinnäytetyön tausta ja tavoitteet

3.1 Toimeksiantaja

Oy Arbonaut Ltd on vuonna 1994 perustettu yritys, joka on erikoistunut luonnonvarojen inventointiin ja hallintaan kaukokartoituksessa. Nykyisin Arbonaut työllistää noin 90 työntekijää Joensuussa sijaitsevassa pääkonttorissa, Helsingin ja Yhdysvaltojen Vermontin toimipaikoissa sekä lisäksi etätyöntekijöitä. Arbonaut käyttää myös alihankkijoita ja tilapäistä työvoimaa eri maissa projektiluontaisissa tehtävissä.

Yrityksen toiminta on jaettu viiteen tiimiin (General, Software business, Forest Inventory, Utility Services ja REDD+ and Sustainable Forestry), jotka toimivat tiiviissä yhteistyössä. Toimitusjohtajana toimii FT Tuomo Kauranne. Inventointitiimissä, jossa tätä opinnäytetyötä toteutetaan, työskentelee noin 10 henkilöä MMT Jussi Peuhkurisen johdolla.

Metsäinventointimenetelmiä käytetään myös REDD+ and Sustainable Forestry -tiimissä (REDD+ on lyhenne sanoista Reducing Emissions from Deforestation and forest Degradation) metsien hiilinieluinventoinneissa. Tällaisten hankkeiden avulla kehitysmaat saavat rahoitusta kansainväliseen ilmastopolitiikkaan nojaten metsiensä suojeluun. Arbonaut on hankkeissa mukana ja vastaa metsävarojen estimoinnista yhteistyökumppaneiden kanssa. Toimintaa on muun muassa Nepalissa, Ghanassa, Laosissa ja Tansaniassa.

Tutkimus- ja kehitystoiminta on olennainen osa yrityksen aktiviteetteja. Yhteistyö eri korkeakoulujen kanssa on Arbonautille tärkeää. Vuoden 2012 aikana on valmistunut tai ollut meneillään kahdeksan opinnäytetyötä tai pro-gradu-tutkimusta.

Yrityksen toimintaympäristö on kansainvälinen. Noin 70 % yrityksen liikevaihdosta tulee viennistä. Eri maista tulevista työntekijöillä on vahvaa osaamista ja suurin osa heistä on rekrytoitu korkeakoulujen vaihto-ohjelmien kautta. Arbonautilla on työntekijöitä yli 20 eri maasta.

3.2 Opinnäytetyön tavoitteet

Aikaisemmissa tutkimuksissa ei ole keskitetty iän ennustamiseen. Myöskään puulajisuhteen estimointi Arbonaut Oy:n nykyisessä tuotantoprosessissa ei ole saavuttanut toivottua tasoa. Joudutaan vielä kehittämään käytettäviä menetelmiä, ennen kuin ennusteiden tarkkuus paranee merkittävästi LiDAR-aineistoa käytettäessä. Tässä tutkimuksessa tarkasteltiin yhtä parannusmahdollisuutta mallinnuksen kehittämisessä.

Opinnäytetyössä testatiin, paraneeko puuston iän ja puulajisuhteiden estimointitarkkuus lisäämällä mallinnukseen asiakkaan kuvioaineiston muuttujia. Työssä arvioitiin, oliko parannus merkittävä tuotannon näkökulmasta ja olisiko syytä ottaa vanha aineisto käyttöön Arbonaut Oy:n inventointiprosessissa, mikäli sellaista aineistoa on saattavilla.

Vanhan kuvioaineiston käyttö laserkeilausperusteisessa metsäinventoinnissa ei ole kovin tavallinen tutkimusaihe. Iän ennustamisen tarkkuuden tutkiminen on jäänyt vähäiseksi myös ilman vanhan kuvioaineiston käyttöä. Puulajin määrittämistä on tutkittu erityisesti yksinpuinmenetelmässä, joka ei ole käytössä Arbonaut Oy:n tuotantoprosessissa. Mm. Packalén ja Maltamo (2006, 2007, 2008) ovat tutkineet kuviotasolla puulajikohtaisten tunnusten ennustamista harvapulssisella laserkeilausaineistolla. Vanhaa kuviotietoa ei ole näissä tutkimuksissa käytetty.

4 Aineisto ja menetelmät

Puustotunnusten estimointiin käytetään Arbonaut Oy:n tavallisessa inventointiprosessissa ensisijaisesti harvaa Bayesiläistä regressiota (sparse Bayesian method) tai k-MSN-estimointimenetelmää. Aineistona käytetään harvapulssista LiDAR-

aineistoa, ilmakuvia ja mitattua maastokoeala-aineistoa. Tämän aineiston perusteella lasketaan selittäviä muuttujia mallinnukseen (laserpisteaineistoa kuvaavia muuttujia, sävyarvo- ja tekstuuripiirteitä ilmakuvulta sekä kasvillisuuden pintamallista). Tässä opinnäytetyössä käytettiin lisäksi puuston ikää sekä puulajisuhteita kuvaavia muuttujia vanhasta kuvioaineistosta.

Tulosten estimoinnissa käytettiin vuonna 2005 tuotemerkiksi rekisteröityä Arbonaut Oy:ssä kehitettyä ArboLiDAR-inventointiprosessia. Opinnäytetyössä käytettiin ArcGIS-järjestelmän versiota 10.0.

Tunnusten estimointi tapahtuu ArboLiDAR-inventointiprosessissa ristiinvalidoinnilla (LOOCV, leave-one-out cross-validation). Menetelmää käyttäen voidaan välttää riippumattoman testaus- tai validointiaineiston (testing data set) käyttö mallinnusaineiston (training data set) rinnalla. Yhdellä koeala-aineistolla voidaan ennustaa muuttujat kaikille koealoille jättämällä kunkin koealan kohdalla kyseinen koeala itse pois selittävien muuttujien joukosta. (Refaeilzadeh, Tang, & Liu 2008, 1–3.)

4.1 Tulkinta-alue

Opinnäytetyössä käytetty aineisto on osa Itä-Suomessa sijaitsevaa inventointialuetta, jonne on tehty puustotulkinta Arbonaut Oy:n toimesta keväällä 2012. Inventointialue on kokonaisuudessaan noin 975 000 hehtaaria laaja, josta 500 000 hehtaaria on metsäalaa. Alue ulottuu Pohjois-Karjalan, Pohjois-Savon ja Kainuun maakuntien alueille. Maastotyössä on kerätty yli 2 000 koealaa. Mänty oli valtapuulaji noin 75 %:ssa koealoista, kuusi noin 20 %:ssa ja lehtipuu noin 5 %:ssa.

Varsinainen tulkinta on tehty erillisenä yksityismailla sekä valtion maille. Tästä tutkimuksesta jätettiin pois ne koealat, jotka ovat yksityismailla tutkimusluvan saannin vaikeuden takia ja keskityttiin Metsähallituksen alueilta mitattuihin koealoihin. Tässä työssä ennustettiin ainoastaan varttuneiden metsiköiden tunnuksia. Varttuneilla metsiköillä tarkoitetaan tässä kehitysluokkia nuori kasvatusmetsä, varttunut kasvatusmetsä ja uudistuskypsä metsä, ja käytetyssä koeala-aineistossa nuorten kasvatusmetsien osuus oli noin 55 %, varttuneiden kasvatusmetsien noin 35 % ja

uudistuskypsi metsien noin 10 %. Metsähallitus antoi luvan käyttää aineistoaan tutkimukseen ja tulosten julkaisuun.

4.2 Maastokoealat

Tutkimuksessa käytettiin painotetulla ja ryvästetyllä satunnaisotannalla valittua 539 maastokoealaa. Packalénin & Maltamon (2006, 619) mukaan sopivan koalamäärän määrittämisessä on omat ongelmansa eli tasapainon löytäminen tavoitetarkkuuden ja kustannusten välillä on hankalaa. Kuitenkin kokemuksensa perusteella he arvioivat koealojen minimimäärän olevan vähintään 100 kpl. Tarvittava määrä nousee kuitenkin, mikäli estimoidaan useampia tunnuksia, kuten tässä tutkimuksessa, ja jos pääpuulaji vaihtelee.

Maastokoealat mitattiin vuoden 2011 maastokaudella Metsäkeskusten toimesta Tapion, Metsäkeskuksen, Metlan ja Itä-Suomen yliopiston yhteisesti kehittämiä maastotyöohjeita seuraten. Maastokoealojen sijainti inventointialueella määritettiin etukäteen ja tarvittaessa koealoja on siirretty niin, että ne eivät sijoittuisi kuvioiden rajoille tai kehitysluokkiin A0, Y1, 05, S0, ja että ne vastaisivat mahdollisimman paljon inventointialueen kuvioittaisten tunnusten jakaumaa. Mittaajat ovat mitanneet yhden työpäivän aikana 6–9 koealaa.

Maastokoalojen sijainnin määrittämiseen on käytetty Metsäkeskusten tiedossa olevia kuviotunnuksia ja tähän tarkoitukseen kehitettyä iteratiivista optimointiohjelmaa. Koealojen sijainti on siirretty maastotallentimelle WGS84-koordinaatistossa. Tavoitetarkkuus sijaintipisteelle oli 0,5 m ja sijaintivirheen oli oltava alle 1 m. Metsikössä navigoitiin tarkasti (alle 2 m) mittauspisteeseen asti sekä GPS- että Glonass-järjestelmiä hyödyntävän GNSS-laitteen avulla. (Heikkilä, Kilpiäinen ja Ärölä 2011, 2-4.)

Koealoilla puut mitattiin ensisijaisesti kalibroidulla ultraääneen perustuvalla etäisyys- ja korkeusmittarilla sekä elektronisilla mittasaksilla, mutta tarvittaessa käytettiin perinteistä hypsometriä ja talmeteriä. Koealojen mittaus toteutettiin parityönä. Koealojen kehitysluokka oli 02, 03 tai 04 ja ne olivat säteeltään 9 metrisiä

ympyräkoealoja, joilta mitattiin jokaisen yli 5 cm:n läpimittaisen puun läpimitta puulajiositteittain. Tämän jälkeen maastotallennin ehdotti jokaiselle puulajiositteille koepuita, jotka olivat pohjapinta-alan mediaanipuita. Koepuilta mitattiin pituus ja ikä. Koepuiden oli oltava terveitä eikä pituudeltaan poikkeavia suhteessa koealan muihin puihin. (Heikkilä ym. 2011 5–7, 17–18.)

4.3 Kaukokartoitusaineisto

Ilmakuvaus on suoritettu 5.6.2011 ja 6.9.2011 välisenä aikana kameratyypillä Vexcel UltraCam Xp. Kuvauskorkeus oli 6 000 metriä, GSD 36 cm, kanta 817 metriä, sivuuspeitto 30 % ja pituuspeitto 80 %.

Ortokuvat on tuotettu käyttäen 40 cm:n pikselikokoa. Kuvaprosessointi on hoidettu UltraMap-ohjelmistolla TerraTec Oy:n toimesta.

Inventointialueen LiDAR-aineisto on kerätty kahdella eri keilaimella. Tähän tutkimukseen otettiin mukaan vaan Leica ALS5011 Lidar Sensor SN58 -keilaimella kerätty aineisto. Aineiston keruu tapahtui 11 lennolla 7.6.2011 ja 7.7.2011 välisenä aikana. Lentokorkeus oli 2 000 metriä ja lentonopeus noin 120 solmua. Avauskulma oli 30 astetta, keilaimen pulssintoistotajuus 52,2–58,9 kHz ja pulssitiheys 0,5–1 pulssia/m².

Mallinnuksessa käytettiin selittävinä muuttujina lidarmuuttujia Lidar30 1–20 ja 27–29 sekä ilmakuvan lähi-infrakanavalta (NIR) ja normalisoidulta kasvillisuusindeksiltä (NDVI, normalized difference vegetation index) laskettuja Haralick-muuttujia, yhteensä 56 muuttujaa.

4.4 Vanha kuvioaineisto

Tässä tutkimuksessa kutsutaan vanhaksi kuvioaineistoksi sitä asiakkaan tietokannasta saatua aineistoa, joka on perinteisellä kuvioittaisen arvioinnin menetelmillä inventoitua tietoa. Vanha kuvioaineisto saatiin Metsähallitukselta tämän tutkimuksen käyttöön. Kuvioittaisen arvioinnin ajankohta vaihtelee suuresti inventointialueen sisällä.

Vanhemmat tiedot ovat vuoden 1988 alusta ja tuoreimmat keväältä 2011. Kuvioita on yhteensä yli 60 000.

Vanhasta kuvioaineistosta käytettiin puulajisuhteita kuvaavina muuttujina puulajikohtaisia tilavuusosuuksia (männyllä VMA_perc, kuusella VKU_perc ja lehtipuulla VLP_perc), eli vanhasta kuvioaineistosta lisättiin kolme muuttujaa mallinnukseen. Tilavuusosuudet liitettiin ArcGis:ssä asiakkaan kuvioaineistosta projektin koeala-aineistoon.

Koealojen ikätieto johdettiin vanhasta kuvioaineistosta. Vanhaan ikätietoon lisättiin mittauspäivän ja tason käsittelypäivän (24.9.2012) erotus omaan sarakkeeseensa. Saatu lukumäärä jaettiin 365,25:llä, jolloin saatiin ikäero vuosina. Tämä tieto lisättiin vanhaan ikätietoon, jolloin tuloksena oli nykypäivän teoreettinen ikä. Muuttuja kuvaa siten metsikön ikää olettamuksella, että metsään ei ole tehty ikään vaikuttavia toimenpiteitä, kuten esimerkiksi avohakkuutta.

Vanhan kuvioaineiston luotettavuus tarkistettiin vertaamalla sen kokonaispuuston keskipituutta laserkeilauksella saatuun pituuteen (LiDAR30_09 eli korkeus 90 % persentiilissä ensimmäisistä kaiuista), jota voidaan pitää melko luotettavana. Vanha kuvioaineisto jaettiin näin luotettaviin ja ei-luotettaviin kuvioihin. On huomioitava, että ainoastaan vanha kuvioaineisto on luotettavaa tai ei-luotettavaa. Muuta aineistoa (maastomittaukset, LiDAR- ja Haralick-muuttujat) pidetään yhtä luotettavana kaikilla koealoilla.

Luotettavan kuviotiedon ryhmään jäi 400 koealaa ja ei-luotettaviin 139 koealaa. Huomattiin, että näin menetellen luotettaviin koealoihin jäi 29 koealaa, joilla kuviotieto oli yli 20 vuotta vanhaa. Näin ollen, vaikka metsikön keskipituudessa ei ole tapahtunut suurta muutosta, on metsässä voinut tapahtua puulajisuhteisiin vaikuttaneita muutoksia, kuten harvennuksessa lehtipuun poisto sekametsästä.

4.5 Tilastolliset menetelmät

Puustotunnukset laskettiin lineaarisella regressioanalyysillä, jolla pyritään löytämään selittävien ja selitettävän muuttujien yhteyttä kuvaava matemaattinen malli. Mallilla ennustetaan selitettävälle muuttujalle arvo eli estimaatti. (Holopainen & Pulkkinen 2008, 260–266.)

Tilastolliset operaatiot suoritettiin ArboLidar-inventointiprosessia seuraten ja tulokset analysoitiin R-ohjelmalla. R on tilastollinen ohjelmointiympäristö, jossa voidaan ohjelmoida tilastollisia menetelmiä tai käyttää muiden kehittämiä menetelmiä. R on vapaa ohjelma, jolle ei tarvita lisenssiä, ja joka voidaan ladata ilmaiseksi internetistä. R:ssä on hyvät graafiset ominaisuudet. (Oksanen 2003, 1.)

Yksi tapa ennustaa useampia selittäviä muuttujia yhtäaikaaisesti on käyttää harvaa Bayesiläistä regressiota (sparse Bayesian regression). Junttilan, Maltamon & Kauranteen (2008, 545) mukaan puustotulkinnassa voidaan käyttää Tippingin (2001) kehittämää menetelmää, jossa valitaan muuttujajoukosta sellainen muuttujayhdistelmä, joka kunkin tunnuksen ennustamisessa toimii parhaiten. Tällä lineaarisella regressiolla voidaan ennustaa puustotunnukset toisistaan riippumatta jokaiselle koelalle.

Ensiksi harvassa Bayesiläisessä menetelmässä valitaan jokaisen koelan jokaiselle tunnukselle (selitettävä muuttuja) ne selittävät muuttujat, joilla on suurin kovarianssi. Oletetaan, että kaikki ennustettavat tunnuksset eivät ole toisistaan riippuvaisia, ja jokaiselle tunnukselle on laadittava oma lineaarinen regressionsa. Lisäksi mitataan mallin tunnuskohtainen paino ja mallin virhe. (Junttila ym. 2008, 545.)

Suurin uskottavuusfunktio saadaan minimoimalla painotetun metsän tunnusten funktion ja estimoitavan vektorin toisen potenssin välinen ero. Korjaus tehdään lisäämällä hyperparametri, joka poistaa ylimääräiset muuttujat antamalla niille painoksi nolla. (Junttila ym. 2008, 545-546.)

Bayesiläinen päättely suoritetaan laskemalla kaikille selitettäville muuttujille posteriorijakauma annetuilla parametreilla. Posteriorijakaumaa sovelletaan aineistolle Tippingin (2001, 215–217) esittämää Bayesiläistä sääntöä soveltaen. Lopuksi

optimoidaan menetelmä maksimoimalla lasketun tunnuksen arvon uskottavuus. Se johdetaan iteroimalla suurimpien uskottavuuksien maksimoinnit annettujen parametrien mukaan. (Junttila ym. 2008, 546.)

Tämän lisäksi tässä tutkimuksessa tehtiin konsistenssi-korjaus, jolla varmistettiin tulosten loogisuus niin, että puulajikohtaiset tunnuksset ja kokonaistunnuksset eivät olleet epäloogisia keskenään. Esimerkiksi puulajikohtaiset tilavuudet yhteensä oli oltava yhtä paljon kuin kokonaispuuston tilavuus.

4.6 Tulosten luotettavuuden arvioinnin menetelmät

Ennusteen tarkkuutta ja luotettavuutta mitattiin keskineliövirheellä (RMSE, Root Mean Square Error, kaava 1.), suhteellisella keskineliövirheellä (RMSE%, kaava 2), harhalla (bias, kaava 3) ja suhteellisella harhalla (harha%, kaava 4). Näitä menetelmiä käytetään yleisesti tulosten tarkkuuden mittaamiseen (esim. Packalén 2009, 24; Hyvönen 2002,369).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (1)$$

$$RMSE\% = \frac{RMSE}{\bar{y}} \times 100 \quad (2)$$

$$Harha = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \quad (3)$$

$$Harha\% = \frac{Harha}{\bar{y}} \times 100 \quad (4)$$

missä n on koealojen määrä, y_i on mitattu tunnus koealalle, \bar{y} havaintojen keskiarvo ja \hat{y}_i on estimoitu tunnus.

5 Tulokset ja tulosten tarkastelu

Tulokset laskettiin puulajisuhteille (PLS_) ja iälle (IKA_) seuraavaksi:

- PLS_A: Kaikki koealat, ei vanhaa kuviotietoa
- PLS_B: Kaikki koealat, vanha kuviotieto mukana
- PLS_C ja IKA_C: Luotettavat koealat, ei vanhaa kuviotietoa
- PLS_D ja IKA_D: Luotettavat koealat, vanha kuviotieto mukana
- PLS_E: epäluotettavat koealat, ei vanhaa kuviotietoa
- PLS_F: epäluotettavat koealat, vanha kuviotieto mukana

Mallinnus on tehty ArboLiDAR-menetelmällä, joka valitsee iteratiivisesti harva Bayesiläinen -menetelmällä jokaiselle ennustettavalle tunnukselle parhaat selittävät muuttujat. On kuitenkin huomattava, että loppuvalinnassa saattaa olla korreloivia muuttujia, mikä heikentää mallin luotettavuutta. Näin ollen, tämän tutkimuksen tulosta ei voi verrata sellaisenaan muissa olosuhteissa laskettuihin tuloksiin, joissa käytettäviä muuttujia on jollain tavalla ennalta valittu tai niiden valintaa on rajoitettu. Arbonaut Oy:n tuotantoprosessissa mallinnuksessa on myös yleensä käytettävissä enemmän muuttujia, joista valinta tehdään.

Tässä tutkimuksessa verrataan keskenään samoissa olosuhteissa ja samalla menetelmällä laskettuja tuloksia. Tulokset ovat sitten vertailukelpoisia.

5.1 Puulajisuhde

Olettamus oli, että apumuuttujat VMA_perc, VKU_perc ja VLP_perc kuvaavat parhaiten eri puulajien tilavuutta (V). Olisi mahdollista laskea puulajien osuuden metsiköstä myös runkolukuna (N) tai pohjapinta-alana (G). Oletettiin myös, että apumuuttujat eivät suoraan kuvaneet keskiläpimittaa (D), keskipituutta (H) tai ikää (T).

Tulosten tarkastelussa katsottiin ensin, miten apumuuttujia on käytetty mallinnuksessa. Seuraavaksi vertailtiin tuloksia tilavuuden ennustamisessa eri vaihtoehdoissa. Sitten laajennettiin vertailu kaikkiin tunnuksiin, jotta saataisiin kuva mallin toimivuudesta

kokonaisuudessaan. Lopuksi vertailtiin myös tuloksia ilman apumuuttujia, jotta olisi mahdollista arvioida, onko vaikutus tuloksiin aiheutunut apumuuttajien käytöstä vai koealamäärän muutoksesta.

5.1.1 Käytetyt vanhan kuvioaineiston muuttajat

Silloin kun kaikki koealat ovat olleet käytössä, vanhasta kuvioaineistosta ei ole otettu muuttujia kokonaispuuston tunnusten estimointiin (Taulukko 3). Muuttujia VMA_perc ja VKU_perc on käytetty joidenkin puulajisuhteita kuvaavien puulajikohtaisten tunnusten estimoinnissa. Muuttujaa VKU_perc on myös käytetty kuusen iän ennustamisessa. Muuttujaa VLP_perc ei ole käytetty ollenkaan.

Taulukko 3. Käytetyt apumuuttajat PLS_B tulosten estimoinnissa.

PLS_B	Kokonaispuusto						Mänty						Kuusi						Lehtipuu					
	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T
VMA_perc									X	X	X												X	X
VKU_perc															X	X	X	X						
VLP_perc																								

Koealojen rajoittaminen luotettaviin on vaikuttanut apumuuttajien käyttöön. Taulukossa 4 havaittiin, että kutakin apumuuttujaa on käytetty vastaavia puulajisuhteita kuvaavien puulajikohtaisten tunnusten ennustamisessa.

Apumuuttujia ei ole edelleenkään käytetty kokonaispuuston tunnusten ennustamisessa. VKU_perc-muuttujaa on myös käytetty kuusen iän määrittämisessä.

Taulukko 4. Käytetyt apumuuttajat PLS_D tulosten estimoinnissa.

PLS_D	Kokonaispuusto						Mänty						Kuusi						Lehtipuu					
	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T
VMA_perc									X	X	X													
VKU_perc															X	X	X	X						
VLP_perc																						X	X	

Epäluotettavien koealojen estimoinnissa (taulukko 5) havaittiin, että puulajikohtaisen tilavuuden muuttujia on käytetty selittäjinä kokonaispuuston iän estimoinnissa, mutta ei esimerkiksi männyn tilavuuden estimoinnissa. Puulajikohtaisia muuttujia on käytetty muidenkin puulajien tunnusten estimoinnissa. Muuttujaa VKU_perc on käytetty ainoastaan männyn pohjapinta-alan ja kuusen pituuden estimoinnissa. Muuttujien valinta ei näytä olevan johdonmukaista.

Taulukko 5. Käytetyt apumuuttujat PLS_F tulosten estimoinnissa.

PLS_F	Kokonaispuusto						Mänty						Kuusi						Lehtipuu					
	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T
VMA_perc						X			X			X			X	X	X	X	X	X				X
VKU_perc										X				X										
VLP_perc						X				X		X			X	X	X	X			X	X	X	X

5.1.2 Tulosten vertailu

Kokonaistilavuudessa pienin RMSE% on saatu luotettavilla koealoilla, joilla apumuuttajat ovat olleet käytössä (PLS_D) (taulukko 6). Parannus ei ollut kovin merkittävä, ja harha oli suurempi lähtötuloksiin (PLS_A) verrattuna. RMSE% ja harha olivat suurempia myös estimoinneissa PLS_B ja PLS_C.

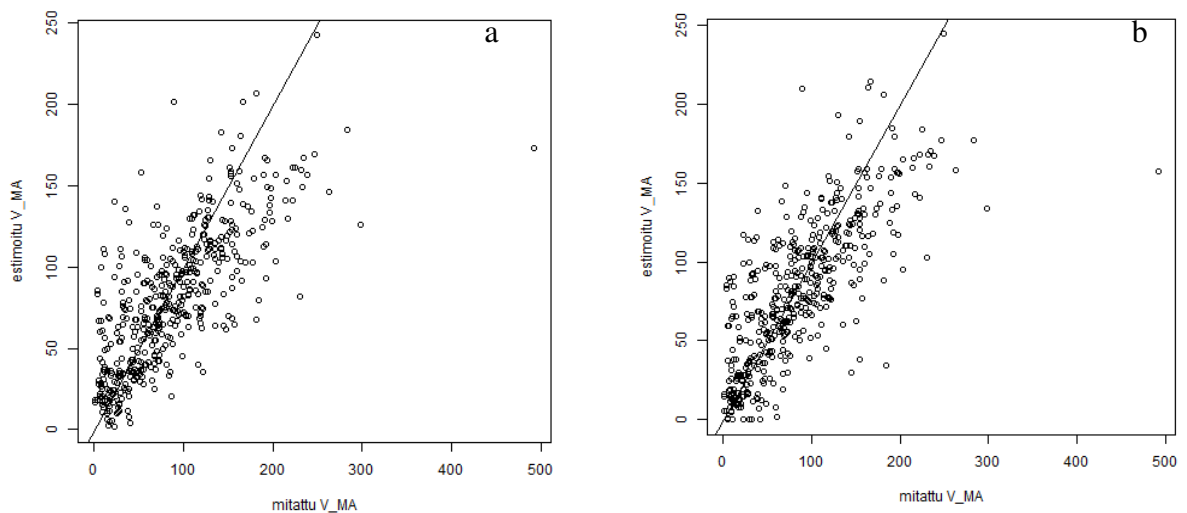
Puulajeittaiset tulokset paranivat melko hyvin männyllä (lähes 5 %) ja kuusella (yli 7 %), kun apumuuttajat olivat käytössä luotettavilla koealoilla (PLS_C ja PLS_D). Lehtipuun tilavuuden ennustamisessa luotettavuus heikkeni melko paljon, kun apumuuttujia käytettiin.

Epäluotettavilla koealoilla ennusteet heikkenivät melko paljon myös silloin kun apumuuttujia ei ole ollut käytössä. Esimerkiksi RMSE% kuusen tilavuusennusteessa oli PLS_A-estimoinnissa 65,96 % ja PLS_E-estimoinnissa 87,84 %. Tulos osoittaa, että koealamäärällä oli suuri merkitys PLS_E- ja PLS_F-estimoinneissa.

Taulukko 6. Eri mallinnustulosten luotettavuus tilavuudessa.

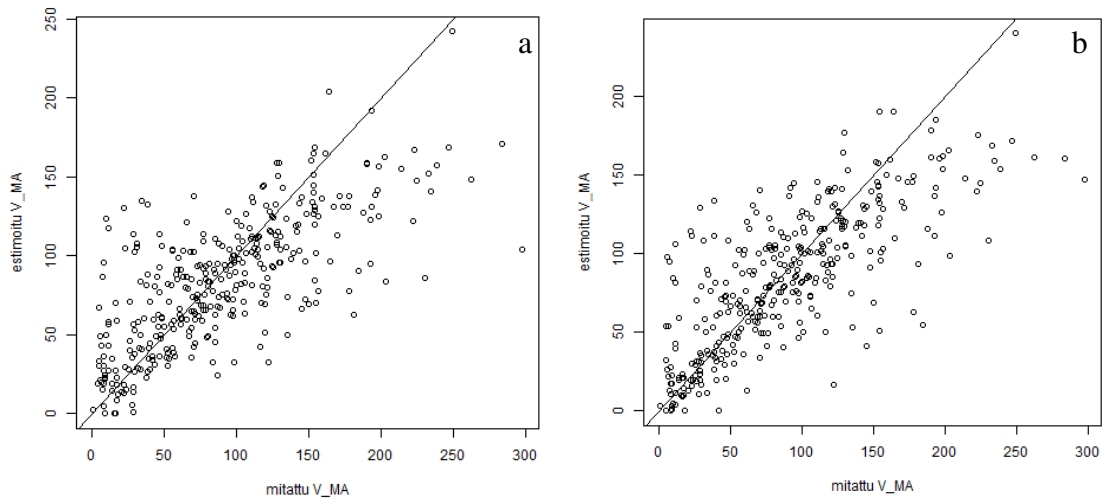
	V		V_MA		V_KU		V_LP	
	RMSE%	Harha	RMSE%	Harha	RMSE%	Harha	RMSE%	Harha
PLS_A	19.48	-0.23	46.96	6.86	65.96	-3.34	103.92	-0.17
PLS_B	19.72	0.84	46.7	4.7	61.97	-5.01	104.88	-0.32
PLS_C	19.63	0.4	44.96	6.47	64.75	-2.37	118.01	0.36
PLS_D	19.42	0.56	42.08	5.13	58.6	-4.27	107.71	0.11
PLS_E	25.24	0.7	55.22	2.64	87.84	-6.72	111.62	0
PLS_F	24.48	-0.24	53.93	0.55	87.87	-7.86	107	-0.27

Kuviossa 1 voidaan havaita silmämääräisesti muutoksia PLS_A:n (a) ja PLS_B:n (b) välillä. Vanhan kuviotiedon lisääminen vähensi yliarviointia männyn tilavuudessa erityisesti koaloilla, joiden estimoitu tilavuus oli alle 50 tai yli 100 kuutiometriä hehtaaria kohti. Toisaalta se lisäsi aliarviointia tilavuudeltaan alle 50 m³/ha koaloilla. Aliarviointi väheni yli 50 m³/ha koaloilla.



Kuvio 1: Mitatun ja estimoidun männyn tilavuus PLS_A:ssa (a) ja PLS_B:ssä (b)

Kuviossa 2 voidaan huomata yliarvioinnin väheneminen koaloilla, joilla estimoitu tilavuus on alle 100 m³/ha ja aliarvioinnin väheneminen koaloilla, joilla estimoitu tilavuus on yli 75 m³/ha. Kuvion 1 b:n ja kuvion 2 b:n välillä voidaan havaita pieni parannus tilavuudeltaan suurempien koalojen yliarvioinnissa ja pienempien koalojen aliarvioinnissa.



Kuvio 2: Mitatun ja estimoidun männyn tilavuus PLS_C:ssa (a) ja PLS_D:ssa (b)

Kun lisättiin vanhasta kuvioaineistosta puulajikohtaiset tilavuudet kaikille koaloille, RMSE% ja harha pienenevät kahdeksan ennustettavan muuttujan kohdalla (taulukko 7). RMSE% parani, mutta harha huononi yhdeksällä tunnuksella, ja molemmat arvot huononivat viidellä tunnuksella. Kahdella harha parani, mutta RMSE% huononi.

Jos otetaan huomioon tunnukset, joiden estimoinnissa on käytetty apumuuttujia (taulukoissa kursivoituna ja lihavoituna), molemmat RMSE% ja harha paranivat viidellä tunnuksella (G_MA, N_MA, V_MA N_KU ja T_KU) ja molemmat arvot huononivat lehtipuun tilavuuden estimoinnissa. Neljällä muulla tunnuksella (G_KU, G_LP ja V_KU) jompikumpi arvoista parani ja toinen huononi.

Parannusta ei ollut havaittavissa tunnusten ryhmissä. Esimerkiksi tilavuus parani hieman männyn osalta, mutta huononi kokonaispuuston ja lehtipuun ennusteissa.

Puulajeittain tarkasteltuna RMSE% parani kaikilla männyn tunnuksilla ja harha kasvoi vain iän estimoinnissa. Kuusella parannus ei ollut yhtä havaittavaa, ja lehtipuun kohdalla estimoinnit huononivat enemmän kuin paranivat. Kokonaispuuston ennusteissa kahden tunnuksen (H ja T) RMSE% ja harha paranivat, kahdella (D ja G) ainoastaan RMSE% parani, kahdella (N ja V) sekä RMSE% että harha huononivat.

Taulukko 7. Tulosten luottavuuden vertailu PLS_A:n ja PLS_B:n välillä.

tunnus	RMSE		RMSE%		harha		harha%	
	PLS_A	PLS_B	PLS_A	PLS_B	PLS_A	PLS_B	PLS_A	PLS_B
D	2.35	2.34	12.97	12.93	0.21	0.22	1.17	1.21
D_MA	3.05	2.89	15.57	14.92	-0.21	-0.14	-1.06	-0.74
D_KU	4.75	4.79	29.85	29.66	-0.3	-0.36	-1.9	-2.26
D_LP	5.95	6.11	58.03	59.64	-1.55	-1.73	-15.11	-16.84
G	3.53	3.52	18.47	18.43	-0.01	0.06	-0.07	0.3
G_MA	5.06	4.89	43.14	42.01	0.39	0.17	3.34	1.48
G_KU	4.51	4.08	56.29	49.41	-0.05	-0.22	-0.57	-2.64
G_LP	3.25	3.3	78.05	78.13	0.25	0.07	5.98	1.64
H	0.86	0.81	6.24	5.93	0.07	0.07	0.48	0.5
H_MA	1.14	1.05	7.98	7.44	-0.1	-0.06	-0.69	-0.44
H_KU	2.7	2.68	21.97	21.54	-0.39	-0.42	-3.14	-3.36
H_LP	4.47	4.53	46.06	46.71	-1.39	-1.5	-14.34	-15.49
N	373.61	375.1	30.95	31.07	1.67	3.95	0.14	0.33
N_MA	306.1	302.79	54.23	53.44	13.02	-1.24	2.31	-0.22
N_KU	321.43	309.12	63.34	59.33	9.84	6.66	1.94	1.28
N_LP	346.67	343.41	98.37	97.44	1.41	1.63	0.4	0.46
T	25.15	24.92	37.94	37.58	0.57	0.35	0.87	0.52
T_MA	26.62	25.08	40.36	38.46	-0.31	-1.06	-0.47	-1.63
T_KU	28.22	28.29	42.11	41.59	-0.43	-0.22	-0.65	-0.33
T_LP	17.8	17.65	40.43	40.23	-0.21	-0.69	-0.48	-1.57
V	26.64	26.97	19.48	19.72	-0.23	0.84	-0.17	0.61
V_MA	40.91	40.25	46.96	46.7	6.86	4.7	7.87	5.46
V_KU	37.81	36.7	65.96	61.97	-3.34	-5.01	-5.83	-8.46
V_LP	20.61	20.8	103.92	104.88	-0.17	-0.32	-0.87	-1.59

Seuraavassa vertailussa (taulukko 8) on käytetty luotettavia koealoja. Kaikista tunnuksista 14:llä sekä RMSE% että harha paranivat tai pysyivät ennallaan ja ainoastaan kolmella tunnuksella (D_LP, H_LP ja T_LP) molemmat arvot huononivat apumuuttujien käytön jälkeen. Kaikki yhdeksän tunnusta, joiden ennustamisessa oli käytetty apumuuttujia, saivat paremman RMSE%-arvon ja kahdella (G_KU ja V_KU) oli huonompi harha.

Puulajeittain katsottuna kaikki männyn tunnuksat paranivat RMSE%-arvon osalta ja vain iän ennustamisessa harha kasvoi. Kuusella ja kokonaispuustolla parannus oli selkeämpi kuin edellisessä vertailussa, eikä yhdellekään tunnuksella ennuste ollut heikompi sekä RMSE%:n että harhan osalta. Lehtipuulla tulos on huonompi, sillä

kolmella tunnuksella sekä RMSE%:n että harhan arvot huononivat. Kolmella muulla tunnuksella molemmat arvot paranivat.

Taulukko 8. Tulosten luottavuuden vertailu PLS_C:n ja PLS_D:n välillä.

tunnus	RMSE		RMSE%		harha		harha%	
	PLS_C	PLS_D	PLS_C	PLS_D	PLS_C	PLS_D	PLS_C	PLS_D
D	2.37	2.36	12.74	12.7	0.19	0.2	1.01	1.05
D_MA	3.41	3.05	17.01	15.29	-0.12	-0.09	-0.58	-0.46
D_KU	4.96	4.98	30.45	30.02	-0.33	-0.18	-2.02	-1.1
D_LP	6.09	6.39	60.07	63	-1.69	-1.95	-16.67	-19.24
G	3.62	3.55	19.01	18.68	-0.02	0.01	-0.09	0.06
G_MA	4.94	4.79	41.33	39.92	0.29	0.12	2.45	0.96
G_KU	4.31	3.79	54.14	47.06	-0.02	-0.1	-0.23	-1.21
G_LP	2.94	2.85	78.51	73.95	0.24	0.18	6.47	4.58
H	0.82	0.82	5.83	5.85	0.06	0.05	0.45	0.35
H_MA	1.14	1.03	7.79	7.06	-0.08	-0.06	-0.54	-0.38
H_KU	2.68	2.66	21.25	20.78	-0.4	-0.34	-3.15	-2.62
H_LP	4.65	4.96	48.53	51.78	-1.45	-1.71	-15.15	-17.82
N	323.84	323.83	28.83	28.83	2.87	7.57	0.26	0.67
N_MA	265.9	261.12	49.35	47.82	4.11	-1.21	0.76	-0.22
N_KU	310.32	300.73	63.32	61.24	11.4	10.75	2.33	2.19
N_LP	268.05	263.97	90.62	89.24	3.91	3.5	1.32	1.18
T	24.26	24.24	35.96	35.93	0.48	0.33	0.71	0.5
T_MA	26.12	25.95	38.99	38.82	-0.33	-1	-0.49	-1.49
T_KU	27.88	27.26	40.81	39.42	-1.24	0.14	-1.82	0.2
T_LP	17.58	18.63	39.71	41.1	-0.02	-0.24	-0.03	-0.53
V	27.18	26.89	19.63	19.42	0.4	0.56	0.29	0.4
V_MA	40.34	37.93	44.96	42.08	6.47	5.13	7.22	5.69
V_KU	37.36	34.29	64.75	58.6	-2.37	-4.27	-4.11	-7.3
V_LP	21.34	19.48	118.01	107.71	0.36	0.11	1.98	0.59

Ei-luotettavien koealojen estimoinnissa (taulukko 9) apumuuttajien lisäys on tuonut parannusta sekä RMSE%:n että harhan arvoihin yhdeksällä tunnuksella ja kasvattanut molempia arvoja kuudella tunnuksella. Muissa tapauksissa jommassakummassa arvossa tuli parannusta. On huomioitava PLS_E- ja PLS_F-tulosten tarkastelussa, että 139 koealaa ei ole riittävä määrä luotettavaan mallinnukseen, kun käytössä on 56 selittävää muuttujaa tai enemmän.

Myös niissä ennusteissa, joissa apumuuttujia on käytetty estimoinnissa, ennusteen luotettavuus ei ole ollut yhtä hyvä kuin luotettavien koealojen tapauksessa. Neljällä sekä RMSE% että harha paranivat, kolmella molemmat arvot huononivat ja lopulla seitsemällä tunnuksella ainoastaan RMSE% parani. Sama ilmiö nousi esiin puulajikohtaisten tunnusten tarkastelussa.

Taulukko 9. Tulosten luottavuuden vertailu PLS_E:n ja PLS_F:n välillä.

tunnus	RMSE		RMSE%		harha		harha%	
	PLS_E	PLS_F	PLS_E	PLS_F	PLS_E	PLS_F	PLS_E	PLS_F
D	2.77	2.79	16.55	16.64	0.28	0.32	1.66	1.92
D_MA	3.08	3.31	17.13	18.7	-0.28	-0.22	-1.55	-1.24
D_KU	4.64	4.86	31.54	32.63	-0.62	-0.64	-4.2	-4.33
D_LP	4.97	4.52	47.06	42.81	-1.2	-1.3	-11.38	-12.26
G	3.55	3.43	18.32	17.68	0.06	-0.04	0.31	-0.19
G_MA	5.32	5.09	49.86	47.75	0.14	-0.26	1.31	-2.4
G_KU	5.53	5.37	65.04	62.28	-0.45	-0.49	-5.31	-5.66
G_LP	4.47	4.13	86.46	79.96	0.14	-0.09	2.79	-1.69
H	1.05	1.02	8.17	7.97	0.15	0.15	1.15	1.18
H_MA	1.15	1.12	8.77	8.65	-0.05	-0.1	-0.4	-0.79
H_KU	2.89	2.86	25.27	24.74	-0.53	-0.5	-4.62	-4.34
H_LP	3.61	3.23	35.76	32.02	-1.04	-0.97	-10.29	-9.64
N	506.43	511.5	34.94	35.29	15.76	-1.01	1.09	-0.07
N_MA	423.83	445.37	68.24	70.53	5.48	-6.41	0.88	-1.01
N_KU	343.27	323.07	58.24	53.82	10.36	26.18	1.76	4.36
N_LP	530.43	506.67	102.92	98.31	8.44	-12.34	1.64	-2.39
T	28.08	26.33	44.59	41.8	1.02	1.18	1.62	1.87
T_MA	29.88	27.72	48.15	45.33	-0.07	-0.06	-0.12	-0.09
T_KU	30.97	31.51	48.08	48.49	-0.09	0.33	-0.14	0.51
T_LP	18.36	15.97	42.67	38.11	-0.49	-0.33	-1.15	-0.8
V	33.29	32.29	25.24	24.48	0.7	-0.24	0.53	-0.18
V_MA	41.03	39.7	55.22	53.93	2.64	0.55	3.55	0.74
V_KU	51.41	52.14	87.84	87.87	-6.72	-7.86	-11.48	-13.24
V_LP	27.76	26.62	111.62	107	0	-0.27	-0.01	-1.07

Tulosten luotettavuuden heikkeneminen ja parantuminen voidaan havaita taulukosta 10. Taulukosta voidaan huomata, että eniten tunnusten luotettavuus parani, kun käytössä oli luotettavaksi luokitellut koealat.

Taulukko 10. RMSE%:n ja Harhan muutokset.

	RMSE% paranee Harha paranee	RMSE% paranee Harha huononee	RMSE% heikkenee Harha paranee	RMSE% heikkenee Harha heikkenee
PLS_A --> PLS_B	8	9	2	5
PLS_C --> PLS_D	14	6	1	3
PLS_E --> PLS_F	9	7	2	6

Kuten on huomattu, sekä apumuuttujien käyttö että koealamäärän muutos vaikuttivat tulosten luotettavuuteen. Seuraavaksi tarkasteltiin molempien toimintojen vaikutusta RMSE%-arvoon. Taulukossa 11 on havaittavissa luotettavuuden ero eri tulosten välillä.

Tulosten luotettavuus parani lähtötulokseen verrattuna 18 tunnuksen ennusteissa estimoinnissa PLS_B, 16 tunnuksen ennusteissa estimoinnissa PLS_C ja 18 tunnuksen ennusteissa estimoinnissa PLS_D. Luotettavin tulos (harmaana taulukossa 11) saadaan kolmen tunnuksen osalta PLS_A:ssa, viiden tunnuksen osalta PLS_B:ssä, kahden tunnuksen osalta PLS_C:ssä ja kolmentoista tunnuksen osalta PLS_D:ssä. Kokonaispuuston runkoluvun ennusteiden RMSE% oli sama estimoinnissa PLS_C ja PLS_D.

Apumuuttujien lisäämisellä (PLS_B) on ollut kolmentoista muuttujan tulosten luotettavuuteen suurempi parantava vaikutus kuin koealojen määrän muutoksella (PLS_C). Parannus on ollut keskimäärin 0,81 %, kun koealamäärän muuttaminen on tuonut 0,29 % parannusta. Samalla keskihajonta on suurentunut enemmän jälkimmäisellä, sillä pienemmällä koealamäärällä lehtipuun runkoluvun ennuste parani yli seitsemällä prosentilla, kun lehtipuun tilavuus huononi neljällätoista prosentilla.

Kun PLS_D-tulokset olivat RMSE%:n osalta 1,77 % parempia kuin PLS_A, johtui 0,29 % koealamäärän muutoksesta ja loppu 1,47 % apumuuttujien lisäämisestä. Kaksikymmentä muuttujaa sai luotettavampia tuloksia PLS_D-estimoinnissa kuin PLS_C:ssa.

PLS_D-estimoinnissa kokonaispuuston tunnuksat paranivat keskimäärin 0,8 % PLS_A-estimointiin verrattuna, männyn osalta RMSE% heikkeni 2,9 %, kuusen osalta 3,7 % ja lehtipuun osalta 0,32 %. Runkolukujen tunnuksat paranivat sekä kokonaispuustossa että puulajeittain keskimäärin melkein viisi prosenttia.

Taulukko 11 RMSE%:n muutosten vertailu tunnuksittain eri tuloksissa.

	RMSE%	erotus					
tunnus	PLS_A	PLS_B - PLS_A	PLS_C - PLS_A	PLS_D - PLS_A	PLS_D - PLS_C	PLS_D - PLS_B	PLS_C - PLS_B
D	12.97	-0.04	-0.23	-0.27	-0.04	-0.23	-0.19
D_MA	15.57	-0.65	1.44	-0.28	-1.72	0.37	2.09
D_KU	29.85	-0.19	0.6	0.17	-0.43	0.36	0.79
D_LP	58.03	1.61	2.04	4.97	2.93	3.36	0.43
G	18.47	-0.04	0.54	0.21	-0.33	0.25	0.58
G_MA	43.14	-1.13	-1.81	-3.22	-1.41	-2.09	-0.68
G_KU	56.29	-6.88	-2.15	-9.23	-7.08	-2.35	4.73
G_LP	78.05	0.08	0.46	-4.1	-4.56	-4.18	0.38
H	6.24	-0.31	-0.41	-0.39	0.02	-0.08	-0.1
H_MA	7.98	-0.54	-0.19	-0.92	-0.73	-0.38	0.35
H_KU	21.97	-0.43	-0.72	-1.19	-0.47	-0.76	-0.29
H_LP	46.06	0.65	2.47	5.72	3.25	5.07	1.82
N	30.95	0.12	-2.12	-2.12	0	-2.24	-2.24
N_MA	54.23	-0.79	-4.88	-6.41	-1.53	-5.62	-4.09
N_KU	63.34	-4.01	-0.02	-2.1	-2.08	1.91	3.99
N_LP	98.37	-0.93	-7.75	-9.13	-1.38	-8.2	-6.82
T	37.94	-0.36	-1.98	-2.01	-0.03	-1.65	-1.62
T_MA	40.36	-1.9	-1.37	-1.54	-0.17	0.36	0.53
T_KU	42.11	-0.52	-1.3	-2.69	-1.39	-2.17	-0.78
T_LP	40.43	-0.2	-0.72	0.67	1.39	0.87	-0.52
V	19.48	0.24	0.15	-0.06	-0.21	-0.3	-0.09
V_MA	46.96	-0.26	-2	-4.88	-2.88	-4.62	-1.74
V_KU	65.96	-3.99	-1.21	-7.36	-6.15	-3.37	2.78
V_LP	103.92	0.96	14.09	3.79	-10.3	2.83	13.13
keskiarvo		-0.81	-0.29	-1.77	-1.47	-0.95	0.52
keskihajonta		1.81	3.73	3.83	3.01	2.95	3.59
mediaani		-0.34	-0.57	-1.37	-0.60	-0.34	0.13

5.2 Ikä

Iän ennustamisen tarkkuus laserkeilausperusteisessa metsäinventoinnissa ei ole tavallisesti kovin korkealla tasolla. Kuten voidaan havaita taulukoista 7 ja 8, kokonaispuuston iän RMSE% on ollut 35,93 ja 37,94 välillä.

Yleisesti asiakkaat ovat pitäneet tärkeämpänä luotettavien tulosten saamista esimerkiksi tilavuudelle ja pohjapinta-alalle hakkuiden ja muiden käsittelyjen suunnittelua varten. Esimerkiksi taulukossa 2 asiakas ei ole määrittänyt estimoinnin tarkkuuden tavoitetasoa iälle. Iän tarkempi ennustaminen on kuitenkin tavoite ArboLidar-inventointiprosessin kehittämisessä, ja sitä testattiin myös tämän opinnäytetyön puitteissa.


Apumuuttujaa on käytetty mallinnuksessa sekä kokonaispuuston että puulajeittaisten ikien ennustamisessa (taulukko 12). Sitä on käytetty lisäksi viiden muun tunnuksen ennustamisessa.

Taulukko 12. Ikä-apumuuttujan käyttö tunnusten estimoinnissa

	Kokonaispuusto						Mänty						Kuusi						Lehtipuu					
	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T	D	H	N	G	V	T
IKA_D			X	X		X	X					X			X			X	X					X

Puulajeittaisessa tilavuuden estimoinnissa on jo havaittu, miten koealojen määrän muutos ja epäluotettavien koealojen käyttö vaikuttaa mallinnukseen. Iän ennustamisen tuloksissa keskityttiin vertailemaan ennustetta, jossa on käytetty luotettavia koealoja ilman apumuuttajaa (IKA_C) ja ennustetta, jossa on käytetty luotettavia koealoja sekä apumuuttajaa (IKA_D).

Kuviossa 3 voidaan havaita melko selkeästi sekä yli- että aliarvioinnin väheneminen kokonaispuuston iän estimoinnissa. Aliarviointi väheni etenkin vanhoissa, yli 100 vuoden ikäisissä puustoissa.



Kuvio 3: Mitattu ja estimoitu ikä IKA_C:ssa (a) ja IKA_D:ssa (b)

RMSE ja RMSE% paranivat kaikissa ennusteissa (kokonaisikä, puulajeittaiset iät), kun apumuuttujaa käytettiin (taulukko 13). Harha ja harha% huononivat kokonaispuuston ja männyn osalta, mutta paranivat kuusella ja lehtipuulla. RMSE% parani 4,65-7,37 prosenttiyksikköä.

Muilla tunnuksilla RMSE%:n arvo parani 0,87-4,79 prosenttiyksikköä, kun apumuuttuja on ollut käytössä. Harha kasvoi kaikilla muuttujilla.

Muiden tunnusten osalta RMSE% huononi yhdeksällä ja parani kuudella. Muutokset eivät olleet kovin suuria: alle 0,5 % kahdellatoista tunnuksella ja kolmella muullakin alle prosentin. Harha huononi seitsemällä, parani viidellä ja oli sama kolmella tunnuksella. Muutokset olivat tässäkin vähäisiä, usein alle 0,1 prosenttia. Lehtipuun runkoluvulla muutos oli paljon suurempi.

Taulukko 13. Tulosten luottavuuden vertailu IKA_C:n ja IKA_D:n välillä.

tunnus	RMSE		RMSE%		harha		harha%	
	IKA_C	IKA_D	IKA_C	IKA_D	IKA_C	IKA_D	IKA_C	IKA_D
D	2.37	2.39	12.74	12.87	0.19	0.19	1.01	1.02
D_MA	3.41	3.15	17.01	15.69	-0.12	-0.06	-0.58	-0.31
D_KU	4.96	4.89	30.45	30.15	-0.33	-0.31	-2.02	-1.89
D_LP	6.09	5.99	60.07	59.07	-1.69	-1.67	-16.67	-16.46
G	3.62	3.21	19.01	16.86	-0.02	0.04	-0.09	0.18
G_MA	4.94	4.84	41.33	40.51	0.29	0.35	2.45	2.91
G_KU	4.31	4.3	54.14	54.47	-0.02	0	-0.23	0.02
G_LP	2.94	2.98	78.51	79.45	0.24	0.24	6.47	6.54
H	0.82	0.82	5.83	5.81	0.06	0.07	0.45	0.49
H_MA	1.14	1.09	7.79	7.46	-0.08	-0.08	-0.54	-0.52
H_KU	2.68	2.75	21.25	21.91	-0.4	-0.39	-3.15	-3.14
H_LP	4.65	4.73	48.53	49.38	-1.45	-1.51	-15.15	-15.74
N	323.84	313.98	28.83	27.96	2.87	1.27	0.26	0.11
N_MA	265.9	267.2	49.35	49.6	4.11	4.62	0.76	0.86
N_KU	310.32	284.9	63.32	58.53	11.4	13.28	2.33	2.73
N_LP	268.05	266.66	90.62	90.15	3.91	0.16	1.32	0.05
T	24.26	20.27	35.96	30.05	0.48	1.12	0.71	1.65
T_MA	26.12	21.18	38.99	31.62	-0.33	-1.02	-0.49	-1.52
T_KU	27.88	24.67	40.81	36.16	-1.24	-0.74	-1.82	-1.09
T_LP	17.58	14.37	39.71	32.47	-0.02	-0.01	-0.03	-0.02
V	27.18	27.55	19.63	19.9	0.4	0.16	0.29	0.11
V_MA	40.34	40.14	44.96	44.75	6.47	6.39	7.22	7.13
V_KU	37.36	37.29	64.75	65.16	-2.37	-2.55	-4.11	-4.46
V_LP	21.34	21.38	118.01	118.24	0.36	0.38	1.98	2.13

6 Päätelmät

On vaikeata osoittaa, mikä tulos on parempi verrattuna johonkin toiseen. Tulosten tarkastelussa huomattiin, että yhden tunnuksen parantaminen lisäämällä muuttujia tai muutamalla koelamäärä saattaa heikentää toisten tunnusten ennusteen luotettavuutta. Mallinnuksessa on kyse kompromisseista eri tunnusten luotettavuuksien välillä. Mallintajan on pyrittävä asiakkaalle sopivimpiin tuloksiin. On huomioitava asetetut painopisteet ja rajoitteet, ja sen perusteella mietittävä, kannattaako säilyttää yhtä tunnusta parantava malli, jos toisen tunnuksen luotettavuus kärsii.

Silloin kun koelamäärä oli riittävä, apumuuttajia oli käytetty johdonmukaisesti sekä puulajisuhteen että iän ennustamisessa. Apumuuttajat kuvasivat ilmiötä kuten oletettiin, eli kutakin apumuuttujaa vastaavaa puulajeittaista tilavuutta tai ikää. Jako luotettaviin ja

ei-luotettaviin koealoihin näyttää perustellulta. Apumuuttujien käyttö ei ollut enää johdonmukaista siinä tapauksessa, jos käytössä oli epäluotettavaa vanhaa kuvioaineistoa ja jos koealamäärä oli pieni. Tässä tutkimuksessa ei voida päätellä kummalla rajoitteella on enemmän negatiivista vaikutusta apumuuttujien käyttöön.

Taulukon 6 vertailun pohjalta voidaan todeta, että luotettavan vanhan kuvioaineiston käytöstä on hyötyä puulajikohtaisen tilavuuden ennustamisessa, kun apumuuttujat ovat riittävästi edustettuna koealatasolla. Eli tässä lehtipuun tulosten huononeminen voidaan selittää sillä, että lehtipuuta ei ollut riittävässä määrin pääpuulajina koealoissa. Huomaamme myös, että koealojen vähentäminen on jossain määrin aiheuttanut parannusta männyn ja kuusen tilavuuden osalta.

Tulosten luotettavuus parani melko hyvin, kun lisättiin vanhasta kuvioaineistosta luotettavaksi luokitellut apumuuttujat. Silloin saatiin RMSE%-arvon osalta paremmat tulokset (18/24 tunnuksen osalta). Suurimmillaan hyöty oli männyn ja kuusen tunnuksilla. Kokonaispuustossa hyöty oli pienempi ja lehtipuulla havaittiin jopa negatiivista vaikutusta. Normaalissa mallinnustilanteessa olisi etsittävä lehtipuulle kuvaavampia muuttujia, jotta saataisiin jonkinlaista kompensatiota. Myös ikää kuvaavan ja luotettavaksi luokitellun apumuuttujan lisääminen on tuonut merkittävää parannus kaikille ikä-tunnuksille.

PLS_E-tulosten tarkasteleminen ja vertailu PLS_A- ja PLS_C-tuloksiin osoittaa, että dramaattinen koealamäärän väheneminen heikensi melko voimakkaasti tuloksia. Vaikka ei-luotettavan vanhan kuvioaineiston lisääminen malliin toi parannusta, on suhtauduttava kriittisesti tulokseen, jossa mallin selittävänä muuttujana on epäluotettavaksi arvioitua tietoa.

Lehtipuun keskihajonta muuttui melko huomattavasti, kun koealamäärää vähennettiin. Lehtipuun tunnusten luotettavaan ennustamiseen tarvittaisiin suurempi koealamäärä.

Edellä esitettyjen tulosten pohjalta voidaan todeta, että luotettavaa vanhaa kuvioaineistoa on hyödyllistä käyttää aputietolähteenä laserperusteisissa metsäinventoinneissa. Tekijä suosittelee menetelmän käyttöönottoa tuotantoprosessiin.

On kuitenkin otettava huomioon useita asioita tämän opinnäytetyön tulosten käytössä. Tulevaisuudessa olisi pohdittava, miten valitaan luotettavat ja ei-luotettavat koealat. Kynnysarvon asettaminen lidarpituuden ja mitatun pituuden erotuksille on yksi mahdollisuus, mutta se ei eliminoi koealoista harvennettuja metsiköitä. Harvennusten vaikutukset voivat kohdistua juuri puulajisuhteisiin, joiden ennustettavuutta tällä menetelmällä pyritään parantamaan. Lisää tarkkuutta voisi antaa jaottelu iän, tiheyden, lehtipuuosuuden ja NDVI-tunnuksen perusteella.

Olisi myös kokeiltava menetelmää normaalissa mallinnuksessa, jossa kaikki mahdolliset muuttujat ovat käytössä ja jossa estetään keskenään voimakkaasti korreloivien muuttujien käyttö. Myös lehtipuun tuloksiin on kiinnitettävä huomiota.

Otannan kattavuutta ei ole tässä opinnäytetyössä ole huomioitu. Tarvittavat koealatyypit on määritelty ennen mittausten alkamista, ja myöhemmässä vaiheessa on tarkistettu, tarvitaanko lisää koealoja, jotta mallinnuksessa olisi käytettävissä edustettava joukko. Tässä työssä poistettiin 139 koealaa alkuperäisestä koealajoukosta tarkistamatta tämän jälkeen koealajoukon kattavuutta vertaamalla jäljelle jäänyttä koealajoukkoa esimerkiksi vanhan kuvioaineiston puustotietoihin.

Vanhan kuviotietoaineiston saatavuus on tarkistettava ennen projektin alkua ja katsottava, että se kattaa kaikki käytettävät koealat ja etteivät koealat sijoittuisi useamman vanhan kuvion alueelle, kuten on ollut joidenkin koealojen osalta tässä tutkimuksessa. Mikäli tarvitaan koealoja alueilta, joilta ei ole vanhaa kuviotietoa saatavilla, on mietittävä miten ratkaistaan ongelma.

Koska lähtöaineisto oli laaja sekä määrältään että maantieteellisesti, keskityttiin opinnäytetyössä testaamiseen ja tulosten analysointiin tällä aineistolla. Tekijän mielestä olisi hyvä kuitenkin testata menetelmää erilaisella aineistolla, jolloin

- a) voidaan vahvistaa tai kumota tekijän päätelmät
- b) voidaan huomioida mahdollinen maantieteellinen vaihtelu
- c) voidaan paremmin havaita kuvion sisäinen vaihtelu, mikäli koealoja olisi enemmän yhdellä kuviolla.

LÄHTEET

- Aronoff, S. & Petrie, G. 2005. Active Sensors: Radar and Lidar. Teoksessa Aronoff, S. Remote sensing for GIS Managers. Redlands: ESRI press. 197–244.
- Haara, A. & Korhonen, K.T. 2004. Kuvioittaisen arvioinnin luotettavuus. Metsätieteen aikakauskirja 4/2004: 489–508.
- Heikkilä, J., Kilpiäinen, S. & Ärolä, E. 2011. Kaukokartoitusperusteisen metsien inventoinnin koalojen maastotyöohje (versio 1.1).
- Holopainen, M. & Pulkkinen, P. 2008. Tilastolliset menetelmät. Helsinki: WSOY Oppimateriaalit Oy.
- Hyvönen, P. 2002. Kuvioittaisten puustotunnusten ja toimenpide-ehdotusten estimointi k-lähimmän naapurin menetelmällä Landsat TM -satelliittikuvan, vanhan inventointitiedon ja kuviotason tukiaineiston avulla. Metsätieteen aikakauskirja 3/2002: 363–379. Teoksessa Hyvönen, P. (2007) The updating of forest resource data for management planning for privately owned forests in Finland. Dissertationes Forestales 38.
- Hyvönen, P. 2007. The updating of forest resource data for management planning for privately owned forests in Finland. Dissertationes Forestales 38.
- Junttila, V., Maltamo, M. & Kauranne, T. 2008. Sparse Bayesian Estimation of Forest Stand characteristics from Airborne Laser Scanning. Forest Sciences 54(5): 543–552.
- Junttila, V., Kauranne, T. & Leppänen, V. 2010. Estimation of Forest Stand Parameters from Airborne Laser Scanning Using Calibrated Plot Databases. Forest Sciences 56(3): 257–270.
- Kangas, A., Päivinen, R., Holopainen, M. & Maltamo, M. 2011. Metsän mittaus ja kartoitus. Silva Carelica 40.
- 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 (2002) 88–99.
- Oksanen, J. 2003. R: Opas ekologeille. Oulun yliopisto. <http://cc.oulu.fi/~tilel/rltk04/Rekola.pdf>. 27.11.2011.
- Packalén, P. 2009. Using airborne laser scanning data and digital aerial photographs to estimate growing stock by tree species. Dissertationes Forestales 77.
- Packalén, P., Maltamo, M. 2006. Predicting the plot volume by tree species using airborne laser scanning and aerial photographs. Forest Science 52(6): 611–622. Teoksessa Packalén, P. (2009) Using airborne laser scanning data and digital aerial photographs to estimate growing stock by tree species. Dissertationes Forestales 77.
- Packalén, P., Maltamo, M. 2007. The k-MSN method for the prediction of species-specific stand attributes using airborne laser scanning and aerial photographs. Remote Sensing of Environment 109:328–341. Teoksessa Packalén, P. (2009) Using airborne laser scanning data and digital aerial photographs to estimate growing stock by tree species. Dissertationes Forestales 77.
- Peuhkurinen, J. 2011. Estimating tree size distributions and timber assortment recoveries for wood procurement planning using airborne laser scanning. Dissertationes Forestales 126.
- Refaeilzadeh P., Tang L., & Liu H. 2008. Cross-Validation. Arizona State University. <http://leitang.net/papers/ency-cross-validation.pdf>. 1.1.2013
- Suvanto, A., Maltamo, M., Packalén, P. & Kangas, J. 2005. Kuviokohtaisten puustotunnusten ennustaminen laserkeilauksella. Metsätieteen aikakauskirja 4/2005: 413–428.

- Tarjouskilpailu 2011. Nordic Commons OY. <http://tarjouskilpailu.fi/tarjouspyynn%C3%B6t/kaikki/Pohjois-Karjala/1/2011-010583/> 10.1.2012.
- Tipping, M.E. 2001. Sparse Bayesian learning and the relevance vector machine. *Journal of Machine Learning Research*. 1 (2001): 211–244.
- Uuttera, J., Anttila, P., Suvanto, A. & Maltamo, M. 2006. Yksityismetsien metsävaratiedon keruuseen soveltuvilla kaukokartoitusmenetelmillä estimoitujen puustotunnusten luotettavuus. *Metsätieteen aikakauskirja* 4/2006: 507–519.