

---

**LASERKEILAUKSEN HYÖDYNTÄMINEN  
HAKKUUTARPEEN MÄÄRITTÄMISESSÄ**



Ammattikorkeakoulun opinnäytetyö

Metsätalouden ko.

Evo, 28.1.2011

Anna Heikkilä



Metsätalouden koulutusohjelma  
Evo

Työn nimi                      Laserkeilauksen hyödyntäminen hakkuutarpeen  
määrittämisessä

Tekijä                              Anna Heikkilä

Ohjaava opettaja              Risto Viitala

Hyväksytty                      \_\_\_\_\_.\_\_\_\_\_.20\_\_\_\_

Hyväksyjä

EVO  
Metsätalouden koulutusohjelma

---

|                  |   |                   |
|------------------|---|-------------------|
| <b>Tekijä</b>    | Anna Heikkilä   | <b>Vuosi</b> 2011 |
| <b>Työn nimi</b> | Laserkeilauksen hyödyntäminen hakkuutarpeen määrittämisessä |                   |

---

## TIIVISTELMÄ

Tässä tutkimuksessa selvitettiin pystytäänkö harvennus- tai hakkuutoimenpidetarve automatisoimaan harvapulssisesta laserpisteaineistosta laskettujen piirteiden avulla. Aineistona on käytetty Evon opetusmetsässä vuonna 2006 keilattua laserpisteaineistoa ja mitattuja referenssikoealoja, joilta on tehty myös toimenpidemääritys. Toimenpidetarvetta tutkittiin logistisella regressioanalyysillä, joka antaa mallin hakkuutoimenpidetarpeen määrittämiseen. Mallin avulla toimenpidetarve voidaan yleistää suuremmille alueille, esimerkiksi kuvioille.

Laserkeilaus on kaukokartoitusmenetelmä, jossa laserkeilain tuottaa pulssin ja rekisteröi paluukaiut. Paluukaiuista voidaan laskea kohteen sijainti ja etäisyys. Kaiut eli laserpisteet muodostavat kolmiulotteisen mallin metsästä, pulssin tiheydestä (pulssia/m<sup>2</sup>) riippuen myös yksittäisistä puista.

Tulosten perusteella mallin avulla voidaan määrittää hakkuutarve oikein lähes 90 prosenttisesti. Koealat, joilla on hakkuutarve, voidaan määrittää oikein 94 prosenttisesti ja koealat, joilla ei ole hakkuutarvetta, voidaan määrittää oikein 73 prosenttisesti. Tulokset vaikuttavat erittäin lupaavilta. Laserpisteaineistosta laskettuja tekstuuripiirteitä voidaan hyödyntää lisää jatkotutkimuksissa.

**Avainsanat** laserkeilaus, hakkuu, harvennus, logistinen regressioanalyysi

**Sivut** 30 s, + liitteet 10 s.

EVO  
Degree Programme in Forestry

---

|                                     |  |                  |
|-------------------------------------|--|------------------|
| <b>Author</b>                       | Anna Heikkilä  | <b>Year</b> 2011 |
| <b>Subject of Bachelor's thesis</b> | Determination of Stand Felling Using Airborne Laser Scanning |                  |

---

ABSTRACT

The objective of the thesis was to find out whether it is possible to automatize a thinning or clear-cutting needs by calculated features from low density pulse data. Material used in the thesis was obtained from airborne laser scanning performed in the educational forest in Evo, Finland. The determination of felling needs was done to the reference plots. Data was analyzed with logistic regression analyses (LRA). LRA determines the best independent variables to the dependent variable. Determination of felling can be derived from the LRA model on greater areas, for example to forest stands.

Airborne laser scanning is a method of remote sensing, in which laser device produces a pulse and registers the returning echoes. Echoes or so called laser points form a three-dimensional model of the forest. Depending on the density of the pulses single trees are also distinguishable.

According to the results the need of felling can be determined correctly in almost 90 per cent of the cases. On reference plots, the need of felling can be determined by 94 per cent, and plots without a need for felling by 73 per cent. The results seem very promising. Texture features calculated from airborne laser scanning data can be used in later studies.

**Keywords** airborne laser scanning, felling, thinning, logistic regression analysis

**Pages** 30 p + appendices 10 p.

# SISÄLLYS

|        |   |    |
|--------|---|----|
| 1      | JOHDANTO.....                               | 1  |
| 1.1.   | Tavoite.....                                | 1  |
| 2      | TUTKIMUKSEN TAUSTAA.....                    | 3  |
| 2.1.   | Kaukokartoitus .....                        | 3  |
| 2.2.   | Laserkeilaus.....                           | 3  |
| 2.3.   | ALS-menetelmä .....                         | 5  |
| 2.4.   | Harvennusmallit .....                       | 6  |
| 2.4.1. | Ensiharvennus.....                          | 7  |
| 2.4.2. | Myöhemmät harvennukset .....                | 7  |
| 3      | AINEISTO.....                               | 9  |
| 3.1.   | Tutkimusalue.....                           | 9  |
| 3.2.   | Laserkeilausaineisto .....                  | 10 |
| 3.3.   | Tekstuuripiirteet .....                     | 11 |
| 3.3.1. | Piirteiden selitykset .....                 | 12 |
| 3.4.   | Maastoreferenssiaineisto .....              | 14 |
| 3.4.1. | Puustotunnukset.....                        | 14 |
| 3.4.2. | Toimenpide-ehdotukset .....                 | 15 |
| 4      | MENETELMÄT.....                             | 17 |
| 4.1.   | Regressioanalyysi.....                      | 17 |
| 4.2.   | Logistinen regressioanalyysi .....          | 17 |
| 4.3.   | Mallin laadinta.....                        | 19 |
| 5      | TULOKSET .....                              | 21 |
| 5.1.   | Piirteet .....                              | 22 |
| 5.2.   | Mallin hyvyys.....                          | 23 |
| 6      | TULOSTEN TARKASTELU JA JOHTOPÄÄTÖKSET ..... | 25 |
| 7      | LOPUKSI .....                               | 27 |
|        | LÄHTEET .....                               | 28 |

|          |  |
|----------|--|
| Liitteet | Logistisen regressioanalyysin tulokset |
| Liite 1  | Havaintojen luokittelu                 |
| Liite 2  | Mallin selitysaste ja yhteensopivuus   |
| Liite 3  | Laserpiirteet                          |
| Liite 4  | Korrelaatiomatriisi ja residuaalit     |

## 1 JOHDANTO

Metsänmittaus on perinteisesti ollut kallista ja hidasta maastotyötä. Menetelmät ovat perustuneet runsaaseen maastotyöhön ja koealamittauksiin. Vasta viime vuosina kaukokartoituksen metsäsovelluksia on kehitetty niin paljon, että niitä on alettu ottaa operatiiviseen käyttöön, ja samalla myös maastotyö on vähentynyt huomattavasti.

Tässä opinnäytetyössä tutkitaan laserkeilauksen hyödyntämistä hakkuutoimenpiteiden määrittämisessä. Metsien kaukokartoituksessa käytettävät menetelmät voidaan jakaa aktiivisiin sekä passiivisiin menetelmiin. Tässä tutkimuksessa keskitytään tarkastelemaan aktiivista menetelmää eli laserkeilaimen lähettämää säteilyä ja sen paluukaikujen analysointia.

Tutkimus keskittyy hakkuutarpeen määrittämiseen ja kohteiden paikallistamiseen uudella menetelmällä. Tutkimuksessa ovat mukana sekä harvennuskohteet että uudistuskypsät metsät. Ensiharvennustarpeen määrittämistä laserkeilausaineiston avulla ovat aiemmin tutkineet muun muassa Vastaranta ym. 2010 ja toimenpidetarpeen määrittämistä kuvioittaisella arvioinnilla sekä kaukokartoitusaineistolla muun muassa Uttera ym. 2002.

Ilmalaserkeilaus tuottaa 3D-pistepilven metsästä. Laserpisteaineistosta voidaan johtaa puustotunnukset metsäkuvioille. Yhdessä ilmakuvioiden tulkinnan kanssa puustotunnusten estimoinnissa päästään jopa tarkempiin tuloksiin kuin perinteisellä kuvioittaisella arvioinnilla (Suvanto ym. 2005). Laserkeilauksella voidaan myös vähentää maastotyön osuutta merkittävästi, jolloin myös kustannustehokkuus nousee.

### 1.1. Tavoite

Tutkimuksen tavoitteena on selvittää pystytäänkö laserpisteaineiston avulla etsimään erilaisia harvennus- ja hakkuukohteita. Tarkoituksena on vertailla ja määritellä aineistosta erilaisia piirteitä, joiden avulla voitaisiin paikantaa hakkuukohteet. Tavoitteena on myös tuottaa aineistoa, jota pystytään hyödyntämään jatkossa laserpisteaineistoa käsitellessä. Jos hakkuutarpeen määrittämisen saisi automatisoitua tutkimuksen mallissa esitettyjen piirteiden avulla, voitaisiin hakkuutarve johtaa suoraan tarkasteltavalle alueelle. Mukana tutkimuksessa ovat sekä harvennus- että pätehakkuukohteet.

Kiinnostuin aiheesta alun perin, kun minua pyydettiin mukaan Helsingin yliopiston tutkimukseen, joka tehtiin yhteistyössä Hämeen ammattikorkeakoulun ja Suomen Akatemian kanssa. Aiheena oli

harvennusten/toimenpiteiden määrityksen luotettavuus perustuen laserkeilausinventointitietoon ja sen piirteisiin. Toimin itse maastotyöntekijänä ja määritimme työparin kanssa yli 700 koealalta toimenpidetarpeen, ajoituksen, kasvupaikkatietoja ym. tunnuksia. Olin myös mittaamassa puustotunnuksia koealoilta kesällä 2009. Tavoitteeni oli tehdä opinnäytetyö, jossa voisin yhdistää ajankohtaisen laserkeilausmenetelmän omaan maastotyöskentelyyni.

Aineistona oli tarkoitus käyttää Evon vuosien 2006 ja 2009 laserkeilausaineistoja, sekä puustotietoja ja toimenpide-ehdotuksia mitatuilta maastokoealoilta Evon opetusmetsän alueella. Vuoden 2009 laseraineisto päätettiin kuitenkin jättää pois analyysistä, koska siitä ei ollut laskettu valmiiksi samoja laserpiirteitä kuin vuoden 2006 laseraineistosta.

## 2 TUTKIMUKSEN TAUSTAA

### 2.1. Kaukokartoitus

Kaukokartoitus (remote sensing) on kohteen (esine, alue, tapahtuma) mittaamista sähkömagneettisen säteilyn avulla ilman fyysistä kontaktia tarkasteltavaan kohteeseen. Jokaisella kohteella on oma tapansa heijastaa, emittoida (lähettää) ja absorboida (imeä) säteilyä. Kohteen heijastamaa ominaissäteilyä käytetään kaukokartoituksessa hyväksi tunnistettaessa kohteita ja tulkittaessa tietoa niiden ominaisuuksista. (Tokola ym. 1998, 1.)


Kaukokartoituksessa käytettävät menetelmät voidaan jakaa aktiivisiin sekä passiivisiin menetelmiin. Passiivinen kaukokartoitus perustuu kohteen itsensä lähettämään säteilyyn (emittointi) tai auringon valon heijastumiseen kohteesta. Aktiiviset kaukokartoitusmenetelmät perustuvat säteilylähteen, esimerkiksi tutkan tai laserkeilaimen lähettämään säteilyyn. (Tokola ym. 1998, 3.) Tässä tutkimuksessa keskitytään tarkastelemaan aktiivista menetelmää eli laserkeilaimen lähettämää säteilyä ja sen paluukaikujen tuottamaa informaatiota.

### 2.2. Laserkeilaus

Laser (light amplification by stimulated emission of radiation) on koherenttia valoa, jonka kaikki aallonpituudet värähtelevät samalla aallonpituudella, samansuuntaisesti ja samalla taajuudella. Laserin tuottamat valoallot ovat tarkasti suunnattavissa tutkittavaan kohteeseen.


Laserkeilaus on aktiivista kaukokartoitusta, jossa laserkeilain lähettää laserpulsseja ja vastaanottaa takaisin heijastuneen kaiun tai kaiut. Laserkeilaus voidaan suorittaa ilmasta käsin lentokoneella tai helikopterilla (airborne laser scanning). Keilainlaite lähettää laserpulsseja, jotka heijastuvat takaisin. Pulssit voivat osua maahan, aluskasvillisuuteen, alikasvokseen, puiden latvukseen, oksiin tai johonkin muuhun. Kun tiedetään lentonopeus- ja -korkeus, keilauskulma, kulkusuunta sekä paluukaiun aika, voidaan laskea kohteen sijainti ja etäisyys satelliittipaikannus- ja inertialaitteiston avulla. Näin jokaiselle pisteelle voidaan määritellä oma kolmiulotteinen (X, Y, Z) sijainti.





Kuva 1 Laserpisteaineistoa Evolta.

Laseraineistossa yksittäinen kaiku luokitellaan kaiun tyyppin mukaan ainoaksi kaikuhavainnoksi, ensimmäiseksi useasta kaikuhavainnosta, välikaiuksi tai viimeiseksi monesta kaikuhavainnosta. Kaiun tyyppiä vastaavat koodit ovat 0, 1, 2, 3. First pulse muodostetaan 0- ja 1-tyypin kaiuista eli ainoista ja ensimmäisistä kaikuhavainnoista. Last pulse muodostuu vastaavasti ainoista ja viimeisistä kaikuhavainnoista eli 0- ja 3-tyypin kaiuista. Näistä pulseista käytetään tässä tutkimuksessa lyhenteitä F ja L. Kuvissa 1 ja 2 on kuvattuna eri väreillä korkeuden mukaan, ensimmäiset, välikaiut ja viimeiset kaiut. Myös yksittäiset puut ja lentolinjan raja erottuvat osittain kuvassa 1.




Kuva 2 Sivukuva laserpisteaineistosta Evolta.

Laserkeilaimen tuottamasta pistepilvestä voidaan muodostaa esimerkiksi maaston pintamalli (DTM, Digital Terrain Model) tai puuston pituusmalli (CHM, Canopy Height Model), jota käytetään yksittäisten puiden tunnistamisessa. Eri korkeuksilla maanpinnasta sijaitsevista pisteistä (Kuva 2) voidaan laskea erilaisia piirteitä, esimerkiksi kumulatiivisesti kerääntyneet prosenttipisteet eri korkeuksilla tai kasvillisuusosuus (yli 2 metrin osumat suhteessa kaikkiin osumiin).

Pituusmallia analysoimalla esimerkiksi hahmontunnistuksen menetelmin voidaan määrittää yksittäisten puiden sijainti, puiden pituus, latvuksen leveys ja puulaji jopa 95 prosentin tarkkuudella (Vauhkonen ym. 2009). Harvoilla pulssitiheyksillä monijaksoisissa metsissä puulajitunnistuksessa saavutetut tulokset ovat parhaimmillaan kuitenkin 75–85 prosentin luokkaa (Hyypä ym. 2009). Edellä mainittujen tunnuksien avulla voidaan laskea kullekin puulle läpimitta, runkoluku, ikä, kehitysluokka, pohjapinta-ala sekä tilavuus. Vastaavat tiedot voidaan laskea koealoille ja kuvioille myös puulajiluokittain. (Hyypä, n.d.)

### 2.3. ALS-menetelmä

ALS-menetelmää (airborne laser scanning) käytetään muun muassa metsien laserkeilauksessa. Keilattavan alueen yli lennetään joko lentokoneella (Kuva 3) tai helikopterilla. Lentokone soveltuu suurien pinta-alojen mittaukseen paremmin ja on nopeampaa sekä edullisempää. Helikopterilla voidaan lentää matalammalla pienempiä alueita ja saadaan tarkempaa tietoa.



Kuva 3 Laserkeilausta lentokoneella. (Heikkilä 2009.)

Laserkeilausaineistoa voidaan tarkastella kahdella eri tavalla riippuen sen pulssitiheydestä: yksittäisen puun tulkinta sekä aluepohjainen tulkinta. Yksittäisen puun tulkinta eli yksinpuintulkinta (esim. Hyypä ym. 2009) tarkoittaa tiheään pulssiin perustuvaa laserkeilausta, eri lähteiden mukaan nykyään riittää 2–3 pulssia/m<sup>2</sup>, kun aiemmin on puhuttu 5–10 pulssista/m<sup>2</sup> (Hyypä & Inkinen 1999). Nykyisin yksittäiset puut saadaan tunnistettua

80–90 prosentin varmuudella jo 2–3 pulssia/m<sup>2</sup> tiheästä aineistosta (Hyypä ym. 2009). Yksinpuintulkinnassa pyritään tunnistamaan yksittäiset puut hahmontunnistuksella, ennustamaan tunnuksat jokaiselle puulle ja lopuksi koostamaan metsikkö yksittäisistä puista.

Aluepohjaista menetelmää käytetään suurien alueiden tulkinnassa, pulssitiheys on pienempi, mutta aineistoa on saatavilla enemmän. Aluepohjaisten menetelmien tulkinta perustuu regressiomallien tai ei-parametristen menetelmien hyödyntämiseen suoraan kuviotasolle, eikä se tarvitse niin tiheäpulsseista laseraineistoa. Regressiomalleja on ensimmäisten joukossa kehittänyt muun muassa norjalainen professori Erik Naeset (2004). Ne perustuvat tilastollisiin riippuvuussuhteisiin, joiden avulla ennustetaan puustotunnuksia koealalle tai kuviolle (Suvanto ym. 2005) laserpisteiden korkeus- ja tiheysjakaumien avulla.

Aluepohjaisten menetelmien vahvuus on harvapulsseisen laserpisteaineiston käyttö. Metsäkeskusten tuleva metsävaratietojärjestelmä perustuu myös tähän menetelmään ja regressiolähestymistapaan, joka tarkoittaa noin 0,5–1 pulssia/m<sup>2</sup>. Regressiomenetelmä on myös halvempi menetelmä kuin tiheää laserpulsseja vaativa yksinpuintulkinta. Regressiomenetelmää voidaan kuitenkin käyttää myös yksinpuintulkinnassa, mutta se vaatii tiheäpulsseista laseraineistoa ja metsiköt koostetaan yksittäisistä puista.

Laserkeilaushankkeen työvaiheita metsätalousovelluksissa ovat keilauksen ja muun muassa lentoratojen suunnittelu, keilaus lentokoneella, referenssikoealojen mittaukset, aineiston käsittely, puustotunnusten mallintaminen ja johtaminen koko metsikköalueelle, ja lopuksi aineiston tarkastus. Maastonmuoto on hyvä ottaa huomioon suunnittelussa, koska se saattaa vaikuttaa keilausmenetelmään. (Ruuskanen 2010.)

### 2.4. Harvennusmallit

Harvennushakkuissa otetaan huomioon niin metsänhoidolliset kuin taloudellisetkin vaikutukset. Harvennustarpeen määrittämisessä käytetään harvennusmalleja. Ne on laadittu puulajeittain ja kasvupaikkatyypeittäin. Tässä tutkimuksessa käytettiin Metsätaloudenkehittämiskeskus Tapion Hyvän metsänhoidon suositusten mukaisia harvennusmalleja. Harvennusten tavoitteena on parantaa puuston laatua, nopeuttaa puuston järeytymistä tukkipuiksi ja tuottaa hakkuutuloja. Tämä onkin koko puunkorjuun ja kasvatuketjun kannattavuuden idea. Harvennusmalleja noudattamalla hakkuissa kertyy ainespuuta niin paljon, että puunkorjuu on taloudellisesti kannattavaa. Harvennuksia tehdään yleensä yhdestä kolmeen kertaan ennen uudistushakkuuta. Harvennusmallien tärkeä tehtävä on toimia myös oppaana koulutuksessa, ammattitaidon ylläpidossa, työpöytäarviointissa ja valvonnassa. (Hynynen ym. 2005, 105.)

Harvennuksissa jätetään kasvamaan terveitä, elinvoimaisia ja tasalaatuisia puita sopivaan tiheyteen harvennusmallien mukaisesti. Harvennusta ei pitäisi viivytellä liian pitkään, koska kasvu hidastuu ja puustoa saattaa

myös kuolla ylitiheyden vuoksi. Tässä tutkimuksessa otettiin huomioon pohjapinta-ala tai runkoluku, läpimitta rinnankorkeudelta, pituus, puulaji ja metsätyyppi. Koealan sijainti kivennäismaalla, suolla, tai turvekankaalla vaikutti jonkin verran ajoituksen arviointiin. Ensiharvennukset, muut harvennukset sekä uudistamiskypsät koealat on arvioitu erikseen.

### 2.4.1. Ensiharvennus

Taimikonhoitovaiheessa pyritään pääsemään sellaiseen runkotiheyteen, että puusto voidaan harventaa noin 12–15 metrin valtapituudessa puulajista riippuen. Ensiharvennus perustuu myös läpimittaan ja tiheyteen, eli runkolukuun. Hyvin hoidetussa männikössä ensiharvennusta voidaan hieman viivyttää kasvun silti alentumatta. Koivikoissa harvennuksen ajankohdassa ei voida joustaa kovinkaan paljon. Latvusten supistumisen ja lisääntyneen tuhoriskin vuoksi harvennusta ei pitäisi lykätä liian pitkälle, vaikka hakkuukertymät hieman kasvaisivatkin. Harvennusta joudutaan aikaistamaan, mikäli taimikonhoito on jäänyt tekemättä tai se on tehty liian lievästi. Ensiharvennukset jälkeen puut, varsinkin kuuset ja rauduskoivut lisäävät voimakkaasti kasvuaan. (Hynynen ym. 2005, 96, 99–100.)

Ensiharvennus on tavoitteiltaan kaksijakoinen, metsänhoidollinen mutta myös taloudellinen. Vaikka hakkuukertymät ja -tulot jäävät melko pieniksi verrattuna tuleviin harvennuksiin, on ensiharvennus tärkeä tekijä metsän järkevässä kasvatuksessa. Kannattavuutta voidaan parantaa lisäämällä poistettavan puuston määrää, korjuukustannukset tippuvat samalla. Voimakas harvennus alentaa kuitenkin kokonaiskasvua aina jonkin verran. Erilaiset tavoitteet, runkojen laatu, järeytyminen sekä harvennuskustannukset ovat osittain ristiriidassa keskenään. Metsänhoito onkin oleellisesti myös metsänomistajan tavoitteista riippuvaa, annettujen rajojen puitteissa. Metsälaki asettaa rajat esimerkiksi liian voimakkaalle harventamiselle. Lakiraja on noin 20–30 prosenttia pienempi kuin harvennusmallien raja. Harventamattomuuteen ja ylitiheyteen laki ei puutu. (Hynynen, ym. 2005, 98–99, 105–106.)

### 2.4.2. Myöhemmät harvennukset

Myöhempien harvennusten ajankohta on joustavammin säädettävissä. Hakkuutulot ovat kuitenkin suuremman puumäärän takia korkeammat ja siten yhtä suuri syy harventamiselle kuin metsän kehityksen ohjaaminenkin.

Muut harvennukset suositellaan tehtäviksi pohjapinta-alaan ja valtapituuteen perustuvien harvennusmallien mukaisesti, yleensä 15–17 metrin valtapituudessa. Malleissa on kaksi kuvaajaa, leimausraja sekä puuston pohjapinta-ala harvennuksen jälkeen. Kun metsikkö yltää ylempään kuvaajaan eli leimausrajaan (korkeampi pohjapinta-ala sekä valtapituus), on harvennus ajankohtainen. Leimausrajan alapuolelle jäävien metsiköiden harvennus ei ole taloudellisesti kannattavaa. Metsikön ylittäessä leimausrajan reilusti on harvennus kiireellinen. Jos puusto

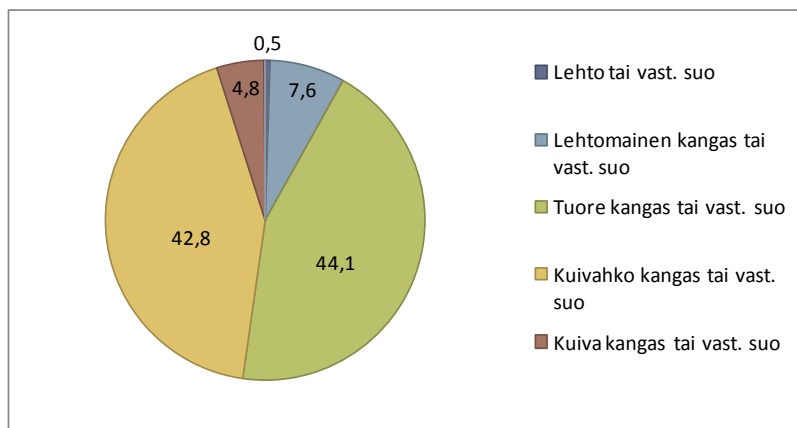
kasvaa liian tiheästi ja latvukset ovat supistuneet, puita kuolee herkästi ja toipuminen kestää kauan. (Hynynen ym. 2005, 105–106.)

Tässä tutkimuksessa uudistamiskypsien koealojen toimenpidemääritys perustui koealan puiden pohjapinta-alalla painotettuun keskiläpimittaan, jotka oli laskettu koealamittausten perusteella, ja Tapion maastotaulukoihin. Päätehakuun tai mahdollisesti toisen kasvatushakuun toimenpidetarve ja kiireellisyys arvioitiin näiden perusteella jokaisella uudistamiskypsällä koealalla.

### 3 AINEISTO

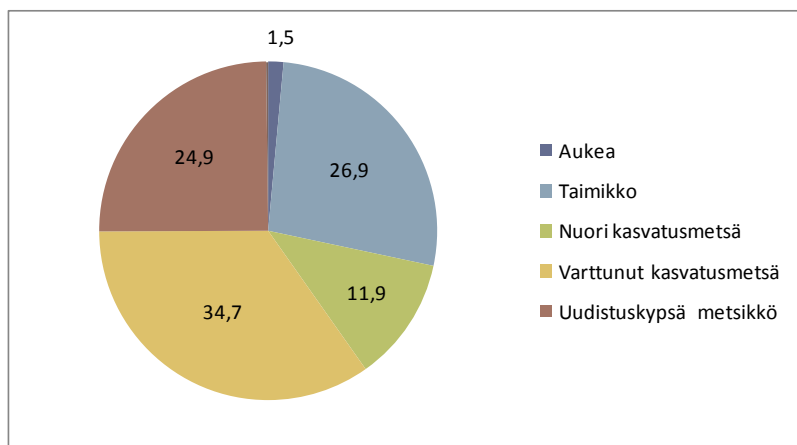
#### 3.1. Tutkimusalue

Tutkimusalue sijaitsee Hämeenlinnan Evolla. Evon opetusmetsä on Hämeen ammattikorkeakoulun sekä Hämeen ammatti-instituutin opetus- ja harjoituskäytössä oleva vajaan 2000 hehtaarin laajuinen Metsähallituksen omistama metsäalue. Se on myös yksi Etelä-Suomen suurimmista yhtenäisistä metsäalueista, jota hyödynnetään ulkoiluun, virkistykseen, tutkimukseen ja opetukseen sekä metsätalouteen.



Kuva 4 Kasvillisuusluokat metsätalouskäytössä olevalla alueella (%).

Evon metsät koostuvat pääosin tuoreista ja kuivahkoista mäntykankaista. Alueen metsätalousmaasta (noin 1700 ha) 44 prosenttia on tuoreita kankaita tai vastaavia soita ja 43 prosenttia kuivahkoja kankaita tai vastaavia soita (Kuva 4). Varttunutta kasvatusmetsää Evolla on 35 prosenttia, taimikkoja 27 prosenttia ja uudistuskypsää metsää 25 prosenttia (Kuva 5). (Metsäsuunnitelma 2006–2015; Raunio, sähköpostiviesti 3.1.2011.)



Kuva 5 Kehitysluokkajakauma metsätalouskäytössä olevalla alueella (%).


Oman toiminnan lisäksi opetusmetsässä on muutakin opetus- ja tutkimuskäyttöä, esimerkiksi Helsingin yliopiston, Metsäntutkimuslaitoksen, Suomen ympäristökeskuksen ja Riista- ja kalatalouden tutkimuslaitoksen tutkimus- ja koetoimintaa, joka on merkittävää oppilaitoksen toiminnalle. Evolla on muun muassa laaja koealaverkosto, jota on käytetty hyväksi monissa metsäalan tutkimuksissa.

### 3.2. Laserkeilausaineisto

Evon laserkeilausaineisto vuodelta 2006 on Blom Kartta Oy:n keräämää ja prosessoimaa. Keilaus suoritettiin kesäkuussa Piper Navajo LN-AEY -lentokoneella. Laserkeilainlaite oli Optech ALTM3100C-EA. Vertikaalinen tarkkuus 1900 metrin korkeudessa oli alle 15 cm ja horisontaalinen alle 40 cm. Pulssitaajuus 70 kHz, avauskulma 14 astetta ja keilan leveys 1090 metriä.

Keilaus suoritettiin kahdelta korkeudelta, koko alue keilattiin ensin 1900 metrin korkeudesta ja lisäksi keilattiin matalalentoalue Evokeskuksen, sekä Rautjärvien läheisyydestä 800 metrin korkeudesta. Pulssitiheydet olivat koko alueelta 0,88 pulssia/m<sup>2</sup> ja matalalentoalueelta 2,65 pulssia/m<sup>2</sup>.

Aineisto on jaettu lohkoihin, joita on yhteensä 64 kappaletta, Evon opetusmetsä rajoittuu 37 lohkon alueelle (Kuva 6). Alueen ylitse kulkee itä-länsisuunnassa 8 kappaletta 45 kilometriä pitkiä lentolinjoja, joista jokaisella on keilattu yksi rivi lohkoja. Jokaisen lohkon koko on 100 hehtaaria. Lentonopeus oli 75 m/s molemmilta korkeuksilta. Keilauksessa luokitettiin 4 kaikutyyppeä; ainoa, ensimmäinen, viimeinen ja välikaiku.



Kuva 6 Opetusmetsän lohkojako.


Jokaisesta kaiusta tallennettiin x-, y- ja z-koordinaatit, korkeus korkeusmallin pinnasta, intensiteetti, kaiun tyyppi ja lentolinjan numero. Blom kartta Oy:n toimittamat ASCII-muotoiset tekstitiedostot sisälsivät nämä tiedot jokaisen lohkon alueesta erikseen. (Komulainen 2009; Lindberg 2009.)

### 3.3. Tekstuuripiirteet

Tutkimuksessa on mukana 102 kappaletta laserkeilausaineistosta laskettuja piirteitä. Piirteet ovat eräänlaisia metsikköä ja sen puita kuvaavia ominaisuuksia. Lähes puolet (48 kpl) piirteistä on tekstuuripiirteitä, joiden laskemista varten laserpisteaineistosta on muodostettu rasteritasoja. Näiltä rastereilta on laskettu ns. Haralickin tekstuuripiirteitä (Haralick 1973, 1979), jotka perustuvat harmaasävyarvojen vierekkäisten esiintymien määrän perusteella määritettyyn yhteneväisyysmatriisiin (Tokola ym. 1998, 80). Ne voidaan laskea SMI-ohjelman avulla.

Rasterin tekstuuria eli pintakuviointia voidaan kuvata pikselien välisten harmaasävyarvojen spatiaalisen riippuvuutena. Tekstuuritunnusten laskentaa on mahdollista lähestyä kahdella eri tavalla: rakenteellisesti tai tilastollisesti. Rakenteellisessa tavassa harmaasävyarvojen spatiaalinen järjestyneisyys pitäisi joko tuntea tai olettaa tunnetuksi, jolloin tapa sopii parhaiten kuvien analysointiin. Kaukokartoituskuville tai rastereille sopii tilastollinen lähestymistapa paremmin, sillä tekstuurin mallia ei voida määrittää varmasti etukäteen.

Yhteneväisyysmatriisista voidaan laskea kaikkiaan 14 eri tekstuuriparametria (Haralick 1973). Parametrit lasketaan matriiseista neljästä eri suunnasta 45° välein (Kuva 5) ja lopullinen arvio on yleensä suuntien keskiarvo. (Tokola ym. 1998, 80–82.)



Kuva 7 Yhteneväisyysmatriisi.

Alla esitetään viisi harmaasävyjä kuvaavaa tunnuslukua: Angular Second Moment (Kaava 1), kontrasti (Kaava 2), korrelaatio (Kaava 3), entropia (Kaava 4) ja alueellinen homogeenisyys (Kaava 5). Ne perustuvat yllä olevaan yhteneväisyysmatriisiin ja sen ruudukoista eroteltuihin pikseliarvoihin. Tutkimuksen tuloksissa esitetyt kuvapiirteet pohjautuvat muun muassa näihin edellä mainittuihin ja seuraavaksi esiteltyihin kaavoihin.



Angular second moment

$$\sum_q \sum_r p^2(q, r) \quad (1)$$

Kontrasti

$$\sum_q \sum_r (q - r)^2 * p(q, r) \quad (2)$$

Korrelaatio

$$- \sum_q \sum_r p(q, r) * \log(p(q, r)) \quad (3)$$

Entropia

$$\sum_q \sum_r (q * r * p(q, r) - \mu_x * \mu_y) / (\sigma_x * \sigma_y) \quad (4)$$

Alueellinen homogeenisyys

$$\sum_q \sum_r p(q, r) / (1 + (q - r)^2) \quad (5)$$

missä:

$$p(q, r) = M(q, r) / Nt$$

$M(q, r)$  = yhteneväisyysmatriisista uudelleen määritellyt pikseliarvot  $q$  ja  $r$

$Nt$  = sävyarvoparien lukumäärä matriisissa

$\mu_x, \sigma_x$  = yhteneväisyysmatriisin keski- ja standardipoikkeamien summa riveillä

$\mu_y, \sigma_y$  = keski- ja standardipoikkeamien summa sarakkeissa

(Viitala & Tuominen, sähköpostiviesti 21.1.2011; Tokola ym. 1998.)

### 3.3.1. Piirteiden selitykset

Seuraavassa esitellään tarkemmin kaikki tämän tutkimuksen logistisen regressioanalyysin malliin mukaan tulevat tekstuuripiirteet. Yli 40 metrin pituudet on poistettu aineistosta häiriöinä, ja metriset pituusarvot on kerrottu 5:llä. Intensiteetit on katkaistu arvoon 255, sitä suuremmat liittyvät yleensä edellä mainittuihin häiriöarvoihin.

h32 – ensimmäisten ja ainoiden pulssien skaalattujen korkeusarvojen (0–255) keskiarvo 32 x 32 rasteri-ikkunaan osuvista yli 2 metrin korkeudelle osuvista pisteistä.

hsxt5 – standarditekstuuri pikseliblokeista, kaikkien pikseliblokkien yhdistetty keskihajonta rasteroiduista laserpituusarvoista.

isxt1 – ensimmäisten (1) ja ainoiden (0) pulssien skaalattujen intensiteettiarvojen (0–255) keskihajonta 1x1 pikselin blokeista.

iasm90 – intensiteetin Angular second movement 90° kulmassa laskettuna (Kaava 1).

hcon135 – skaalattujen korkeusarvojen laskevan diagonaalin yhteneväisyysmatriisin arvoista on laskettu kontrastiarvo (Kaava 2).

icon0 – skaalattujen intensiteettiarvojen horisontaalisen yhteneväisyysmatriisin arvojen kontrastiarvo (Kaava 2).

ient0 – skaalattujen intensiteettiarvojen horisontaalisen yhteneväisyysmatriisin arvojen entropia-arvo (Kaava 4).

hhom135 – skaalattujen korkeusarvojen laskevan diagonaalin yhteneväisyysmatriisin arvoista laskettu homogeenisuusarvo (Kaava 5).

(Viitala & Tuominen, sähköpostiviesti 21.1.2011.)

### 3.4. Maastoreferenssiaineisto

#### 3.4.1. Puustotunnukset

Maastokoealojen mittauksen ovat tehneet Hämeen ammattikorkeakoulun opiskelijat kolmessa eri vaiheessa: kesä–joulukuussa 2007, syksyllä 2008 sekä kesällä 2009. Mittaukset tehtiin pääosin kahden tai kolmen hengen ryhmissä. Vuonna 2007 mitattiin 283 koealaa, 2008 mitattiin 85 kappaletta ja vuonna 2009 yhteensä 468 koealaa. Yhteensä Evon koealaverkosto sisältää 836 kappaletta 300 neliömetrin (halkaisija 9,77 metriä) ympyräkoalaa. Mukana tässä tutkimuksessa ovat vuonna 2007 mitatut koealat, joiden laserkeilaus on tehty vuonna 2006.

Mukana mittausryhmällä oli maastokartta sekä retki-GPS, johon mitattavien koealojen koordinaatit syötettiin. Koealan keskipiste määritettiin paikkaan, jossa GPS-paikannin näytti ensimmäisen kerran nolla metriä. Maahan pystytettiin koealan keskipisteen kohdalle 30 cm pitkä oranssi muoviputki, johon kirjattiin koealanumero. Viereen työnnettiin myös 100 mm pitkä rautanaula tai iso prikka, jotta koeala löytyisi myöhemmin metallinpaljastimen avulla, mikäli keskipiste olisi hävinnyt. Tämän jälkeen kirjattiin lähestymisohje koealalle eli merkittiin spraymaalilla 2–3 maamerkkiä, esimerkiksi kiviä, ja niiden suunnat sekä etäisyydet keskipisteestä. Näin koealalle olisi helpompi suunnistaa myöhemmin.

Mitatessa ensimmäinen mittaja seiso i koealan keskipisteessä ja mittasi bussolilla suunnan puun ytimeen. Toinen mittaja asetti transponderin eli Vertex-vastaanottimen puun kylkeen 1,3 metrin korkeuteen, numeroi puun spraymaalilla sekä mittasi läpimitan mittasaksilla millimetrin tarkkuudella. Keskellä oleva mittaja mittasi etäisyyden puun syntypisteeseen. Etäisyyden ja pituuden mittaus tapahtui Haglöfsin Vertex II -laitteella.

Ensimmäinen mittaja mittasi lopuksi puun pituuden, sekä kasvukoealoilla kolmen viimeisen vuoden pituuskasvun. Kolmen hengen ryhmässä, kolmas henkilö kirjasi mittaustulokset maastotallentimeen.

Koealalta kerättiin tarkat GPS-havainnot Trimblen GeoXH -laitteella, keskipisteestä otettiin vähintään 50 havaintoa. Differentiaalikorjaukset tehtiin jälkikorjauksena mitattuihin havaintoihin GPSNet.fi-palvelun Hämeenlinnan tukiaseman tietojen avulla. Hyvissä olosuhteissa laitteella päästiin korjausten avulla alle 30 senttimetrin tarkkuuteen, keskivirheen ollessa noin 0,6 metriä.

Mittausohjeet ovat muuttuneet eli ne ovat olleet hieman erilaiset eri vuosina. Vuonna 2006 (mitattu 2007) ja 2008 mitatuilla koealoilla puiden minimiläpimitta oli 5 cm, kun taas vuonna 2009 mitatuilla minimiläpimitaksi valittiin 7 cm. Vuoden 2007 koealoilla mitattaviin tunnuksiin sisältyi myös latvuksen läpimitan mittaus, mutta 2009

latvusläpimittaa ei mitattu. 2009 mitattiin kuitenkin kasvukoealoilta viimeisen kolmen vuoden pituuskasvu ensisijaisesti kahdesta suurimmasta havupuusta, koepuut myös kairattiin rinnankorkeudelta jatkotutkimuksia varten.

### 3.4.2. Toimenpide-ehdotukset

Maastossa tehtiin toimenpide-ehdotukset kaikille koealoille marras- ja joulukuussa 2009. Käytännössä maastotyö toteutui suhteellisen nopeasti, päivässä arvioitiin yhteensä noin 30–45 koealaa. Maastotyötekijänä toimin itse yhdessä työparin kanssa. Koealat jaettiin suurin piirtein puoliksi ja arvioitiin yksin. Koealoilta määritettiin lumitilanne, kehitysluokka, metsätyyppi, suoryhmä, ojitustilanne, pääpuulaji, toimenpide, ajoitus, peruste sekä tarkenne.

Määritettäviä koealoja oli alussa enemmän, niistä jäi kuitenkin osa pois jo suunnitteluvaiheessa, koska niiden todettiin olevan esimerkiksi vesialueita tai muita puuttomia alueita. Koealoja jäi pois myös sen takia, että koealan keskipistettä tai merkittyjä puita ei löytynyt maastosta. Nämä koealat kirjattiin kuitenkin ylös.

Maastossa mukana olivat maastokartta, koordinaatit koealoille, retki-GPS (Garmin XC60), relaskooppi, Tapion Hyvän metsänhoidon maastotaulukot, Psion-maastotallennin, sekä aluksi taimikonmittaukseen soveltuva 4 metrin koottava mittakeppi; joka jätettiin pian pois, koska taimikot eivät olleet oleellisin asia näiden toimenpide-ehdotusten puitteissa. Hakkuutoimenpiteet olivat etusijalla työn toimeksiantajan tutkimuksessa.

Ensin valittiin kartalta sopiva koealarypäs ja sen jälkeen syötettiin koordinaatit GPS-paikantimeen. Lähestyttäessä koealaa paikantimen kanssa, pystyi jo kauempaa hahmottamaan koealan puustoa sekä mahdollista toimenpidetarvetta. Koealan keskipisteet oli merkitty oranssilla muoviputkella, jossa oli myös koealan numero. Keskipisteen löydyttyä arvioitiin koeala silmämääräisesti, katsottiin pituus, läpimitta ja pohjapinta-ala mitatuista puustotiedoista. Mikäli puustotiedot puuttuivat koealalta tai mahdollisissa epäselvissä tapauksissa otettiin vielä relaskoopilla suuntaa antava pohjapinta-ala mahdollisen harvennuksen ajoituksen arvioimiseksi. Toimenpiteet määritettiin Tapion Hyvän metsänhoidon suositusten ja harvennusmallitaulukoiden mukaisesti.

Pohjapinta-alan mittaukseen relaskoopilla ei voinut kuitenkaan luottaa liikaa, koska ympyräkiekalan säteen ollessa vain 9,77 metriä mukaan olisi tullut liian vähän puita. Tarkoitus oli tehdä arvio nimenomaan koealan sisältä eikä ympäröivästä metsästä. Tulokset saattavat näin ollen poiketa jonkin verran esimerkiksi metsäsuunnitelman kuviotiedoista. Puustoltaan samankaltaisilla kuvioilla saattaa olla paikoittain vaihtelua muun muassa puuston tiheydessä ja kasvupaikassa.

Koealalle saavuttaessa määriteltiin ensimmäiseksi lumitilanne (lunta, ei lunta), koska maassa mahdollisesti oleva lumi vaikeutti metsätyypin

tunnistamista opaskasvien jäädessä tällöin lumen peittoon. Hakkuun ajoitus määritettiin arvioidun pohjapinta-alan, harvennusmallien sekä puuston arvioidun kasvun perusteella. Toimenpiteelle määritettiin ajoituksen lisäksi myös peruste sekä tarkenne. Peruste määritettiin suurin piirtein sen perusteella, oliko kohde yli tai alle leimausrajan vai rajatapaus, jossa kohde oli mahdollisesti juuri leimausrajalla. Rajatapauksissa toimenpiteen ajoitus siirtyi yleensä myöhäisemmäksi kuin yli harvennustarpeen olevilla koealoilla. Tarkenteeseen lisättiin vielä koodi, mikäli puustossa oli jotain ylimääräistä huomautettavaa sen kunnossa tai laadussa.

Arvioidut metsikkötunnukset tallennettiin jokaisella koealalla Psion-maastotallentimeen edelleen Excel-taulukkoon. Tallennetut koealat purettiin säännöllisesti useamman kerran viikossa tietokoneelle varmuuskopioiden tekemiseksi ja tietojen katoamisen estämiseksi.

## 4 MENETELMÄT

### 4.1. Regressioanalyysi

Regressioanalyysin avulla pyritään selittämään tiettyä selitettävää muuttujaa yhden tai useamman selittävän muuttujan avulla. Tässä tutkimuksessa oli mukana useita selittäjiä. Parhaat piirteet eli selittävät muuttujat kuvaamaan tiettyä selitettävää muuttujaa esimerkiksi hakkuutarvetta saadaan askeltavalla regressiolla.

Askeltava regressio voidaan tehdä eteen- tai taaksepäin. Eteenpäin askeltavassa regressiossa malliin sijoitetaan aluksi vain vakio ja aletaan lisätä malliin selittäviä muuttujia siinä järjestyksessä, kuin ne kasvattavat eniten mallin valintakriteeriä. Esimerkiksi muuttuja, jolla on suurin t-testin arvo, lisätään malliin. Kierroksen jälkeen aletaan alusta ja lisätään seuraavaksi eniten selitysastetta kasvattava muuttuja jne.

Taaksepäin askeltavassa regressiossa malliin valitaan ensin kaikki selittävät muuttujat ja aletaan poistaa muuttujia yksi kerrallaan. Ensimmäinen poistetaan esimerkiksi muuttuja, jolla on pienin t-testinarvo. Askellus jatkuu niin kauan kunnes selitysaste ei enää parane poistamalla muuttujia. Eteen- ja taaksepäin askeltavilla regressioilla ei välttämättä tule samanlaisia malleja, koska kun selittäviä muuttujia on paljon, askellus loppuu yleensä selitysasteen lokaaliin maksimiin. (Haapanen 2010.)

Regressioanalyysin kaava:

$$y = a+bx, \quad (6)$$

missä a on vakiotermi, b regressiokerroin ja x selittävän muuttujan arvo.

### 4.2. Logistinen regressioanalyysi

Logistisen regressioanalyysin (Logistic Regression Analysis, LRA) avulla pyritään löytämään parhaat selittäjät useiden joukosta selittämään ilmiötä ja siinä tapahtuvaa vaihtelua tilanteessa, missä selitettävä muuttuja on luokittelumuuttuja (Metsämuuronen 2005, 687). Tässä tutkimuksessa muuttuja on dikotominen, hakkuutarve joko esiintyy aineistossa tai ei. Hakkuutarve voitaisiin jakaa myös kiireellisyysluokkiin, tällöin selitettävä muuttuja olisi moniluokkainen.

Logistisessa regressioanalyysissä kuvataan ilmiön tapahtumisen todennäköisyyden ja selittävän muuttujan välinen yhteys logistisella jakaumalla (Yli-Kojola 2005, 17). Sillä pyritään ennustamaan todennäköisyyksiä esimerkiksi, kuinka hyvin maastossa määritetyt harvennettavat koealat sijoittuvat oikeisiin luokkiin. LRA:n ymmärtämiseksi täytyy tietää, mitä tarkoitetaan riskillä (odds). Riskilukuja

käytetään kuvattaessa vedonlyönnin voittosuhteita. Riski saadaan suhteuttamalla tapahtuman todennäköisyys siihen, että se ei tapahdu. Riskiluku voi saada arvoja nollan ja äärettömän välillä. LRA:ta varten otetaan riskistä luonnollinen logaritmi. Yksinkertaisesti logistinen regressiomalli on tavallinen regressiomalli, jossa selittävänä muuttujana on tutkittavan tapahtuman riskin logaritmi. (Mattila 2009.)

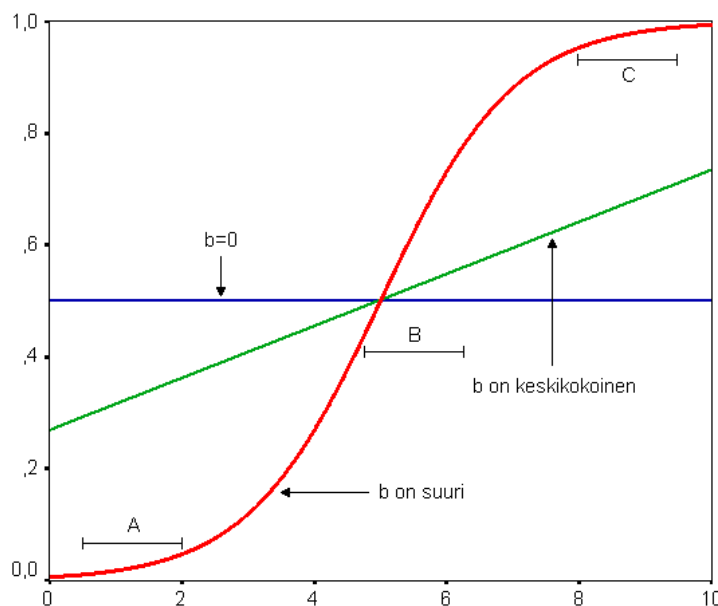
Logistisen regressioanalyysin kaava:

$$P = \frac{e^{a+bX}}{1 + e^{a+bX}} \quad (7)$$

missä e on neperin luku, a vakio-termi, b regressiokerroin ja x selittävän muuttujan arvo.

LRA:n kaavassa (7) a+bx on täsmälleen sama kuin normaalissa regressioanalyysissä. Siksi molempiin regressioanalyysihin liittyvät ongelmat sekä niiden tulkinta ovat samankaltaisia, joskin logistisen regression tulosten tulkinta on hieman hankalampaa. Tämä johtuu siitä, että LRA:ssa selitettävän muuttujan todennäköisyyden muutos riippuu b-kertoimen lisäksi selittävän muuttujan arvosta. Tavallisessa regressioanalyysissä yhden yksikön muutos selittävässä muuttujassa aiheuttaa aina samansuuruisen muutoksen myös selitettävässä muuttujassa. (Mattila 2009.)

Tulkinnassa täytyy kuitenkin ottaa huomioon, että LRA:ssa selittävien ja selittävän muuttujan suhde ei ole lineaarinen, vaan enemmänkin S-käyrän muotoinen. Kuvassa 8 on esitetty esimerkki logistisista käyristä. Logistisen regressioanalyysin tulos on Y-akselilla. Se saa arvoja 0 ja 1 väliltä.



Kuva 8 Logistista regressioanalyysiä kuvaavia käyriä.

Jos selitettävällä ja selittävällä muuttujalla ei ole lainkaan yhteyttä toisiinsa, saa regressiokerroin  $b$  itseisarvoltaan hyvin pienen arvon. Kuten yllä olevasta kuvasta nähdään, on muuttujien yhteyttä kuvaava käyrä täysin vaakasuora, kun  $b$  saa arvon nolla. Se tarkoittaa, että todennäköisyys tapahtumalle ei muutu selittäjän arvojen vaihdellessa. Kun, käyrä on S-kirjaimen muotoinen kerroin  $b$  saa suuren arvon. Jos selittävän muuttujan pieni arvo tai lähellä ylärajaa oleva arvo (välit A ja C) muuttuu hieman, ei selitettävän muuttujan mittaama tapahtuman todennäköisyys muutu paljoakaan. Mutta jos selittävä muuttuja saa arvoja vaihteluvälin keskivaiheilta (väli B), pienikin muutos aiheuttaa suuren muutoksen selitettävän ilmiön tapahtumistodennäköisyydessä. (Mattila 2009.)

Logistisella regressioanalyysillä voidaan tutkia ja etsiä monien muuttujien joukosta niitä tekijöitä, jotka yhdessä kykenevät selittämään parhaiten jotakin selitettävää muuttujaa, joka voi saada kaksi tai useampia toisensa poissulkevia arvoja. Tai sillä voidaan tutkia jo aiemmin tärkeäksi tiedettyjen muuttujien osuutta selventävinä tekijöinä. Lisäksi voidaan testata myös, olisivatko jotkin tietyt tekijät parempia selittäjiä kuin toiset. Tässä tutkimuksessa testataan millä laserpiirteillä pystytään parhaiten selittämään selitettävää muuttujaa eli harvennus- tai toimenpidetarvetta. Sen lisäksi pyritään selvittämään millaisia riippuvuuksia valituksi tulleilla piirteillä on toisiinsa ja selitettävään muuttuun nähden. (Metsämuuronen 2005, 687–688.)

### 4.3. Mallin laadinta

Harvennusmalli laadittiin logistisella regressiolla, jossa selitettävänä muuttujana oli hakkuutarve. Hakkuutarve on dikotominen muuttuja, eli se voi saada vain kaksi arvoa, 1 merkitsee hakkuutarvetta ja 0 ei hakkuutarvetta. Malli antaa harvennuksen tai toimenpiteen esiintymisen todennäköisyyden selittävien muuttujien eli piirteiden avulla. (Yli-Kojola 2005, 18.) Käytännössä mallilla voidaan ennustaa alueita, joilla esiintyy pikaista hakkuutarvetta tai hakkuutarvetta ei esiinny ollenkaan. Tässä tutkimuksessa selittävinä muuttujina käytettiin laserpisteaineistosta valmiiksi laskettuja piirteitä.

Tutkimusaineiston analyysissä käytettiin SPSS-ohjelmistoa, joka on tilastoanalyysiohjelma. Mukana oli kaikkiaan 229 koealaa, joilta havainnot tehtiin. Taimikot eli toisin sanoen alle kahden metrin kasvillisuusosuus on poistettu tutkimuksessa mukana olevasta aineistosta. Selittäviä piirteitä luettiin mukaan yhteensä 102 kappaletta. Mallin laadinta aloitettiin testaamalla muuttujien yhdistelmät parhaan selitystason saamiseksi. Ensimmäiseksi luettiin kaikki muuttujat sisään malliin, ja siitä eteen- tai taaksepäin askeltavalla menetelmällä muuttujia joko lisättiin tai poistettiin mallista. Jos muuttujan lisääminen paransi mallin selitystasetta, se lisättiin ja mikäli muuttujan poistaminen paransi selitystasetta, se poistettiin. Näin jatkettiin, kunnes lisämuuttujat eivät tuoneet malliin enää uutta informaatiota.



Regressiomenetelmäksi valittiin tässä tutkimuksessa likelihood-ratio (LR)-testisuure, joka määrittää muuttujien poistamisen ja lisäämisen malliin, sekä eteenpäin askeltava menetelmä.

LR-testissä verrataan log-likelihood-arvoa ennen ja jälkeen muuttujan poistamisen mallista. Jäljelle jääneet, selitysvoimaltaan tilastollisesti merkitsevimmät muuttujat muodostavat tilastollisessa mielessä parhaan mallin. Vähiten muuttujia sisältävä malli ei välttämättä olekaan kaikkein paras. On otettava myös huomioon mahdolliset multikollineariset muuttujat, jotka teknisesti selittävät yhtä paljon selitettävän muuttujan vaihtelusta, mutta eivät tuo siihen lisäarvoa. (Metsämuuronen 2005, 693.)

## 5 TULOKSET

Tutkimuksessa oli mukana yhteensä 229 havaintoa joista 56 havaintoa arvioitiin maastossa, ei hakkuutarvetta -luokkaan (0) ja 173 havaintoa, hakkuutarve-luokkaan (1). Tutkimuksen koelajoista suurin osa sijoittui ensiharvennus- ja harvennuskohteilla, uudistuskypsille alueille sijoittui vain kolmasosa koelajoista. Mukana olivat sekä kivennäismaat että turvekankaat, ja metsätyypit vaihtelivat lehtomaisesta kankaasta kuivaan kankaaseen tai vastaaviin soihin. Koelat sijoittuivat koko opetusmetsän alueelle.

Logistisen regressiomallin antaman ennusteen avulla voidaan kukin havainto luokitella kahteen ryhmään. Jos  $P$  (ennustettu todennäköisyys)  $< 0.5$  niin havainto sijoittuu ryhmään 0, ja vastaavasti, jos  $P > 0.5$ , niin ennustetaan, että havainto kuuluu ryhmään 1. Jos  $P = 0.5$ , voidaan arpoa, kumpaan ryhmään havainnon ennustetaan kuuluvan.

Toimenpidettä tarvitsevat kohteet malli kykeni ennustamaan oikein 94 prosenttisesti. Kaikissa tapauksissa luokitus onnistui lähes 90 prosentilla havainnoista. Ei hakkuutarvetta -luokkaan, kuuluvat voitiin ennustaa mallin avulla oikein 73 prosenttisesti. Hakkuutarve, joka oli maastossa arvioitu 173 koelalle, pystyttiin mallin avulla ennustamaan oikein 163 koelalle (94 prosenttia). Koelajoja, joille ei maastossa ollut määritetty hakkuutarvetta, oli 56 kappaletta. Näissä tapauksissa mallilla pystyttiin ennustamaan luokitus oikein 73 prosenttisesti eli 41 koelalle. Kaikissa tapauksissa luokitus onnistui lähes 90 prosenttisesti (Taulukko 1 ja Liite 1).

Taulukko 1 Havaintojen luokittelu.

| Observed |                    | Predicted      |     |                    |
|----------|--------------------|----------------|-----|--------------------|
|          |                    | harvennustarve |     | Percentage Correct |
|          |                    | 0              | 1   |                    |
| Step 11  | harvennustarve 0   | 41             | 15  | <b>73,2</b>        |
|          | 1                  | 10             | 163 | <b>94,2</b>        |
|          | Overall Percentage |                |     | <b>89,1</b>        |

### 5.1. Piirteet

Malliin mukaan tulevat hakkuutoimenpidetarvetta selittävät piirteet ja niiden arvot ovat lueteltuna alla olevassa taulukossa sekä liitteessä 3. Kun nämä piirteet ja niiden arvot sijoitetaan logistisen regressioanalyysin kaavaan (7), voidaan ennustaa hakkuutarve suuremmille alueille, joilta on myös laskettu samat piirteet.

Taulukko 2 Malliin mukaan tulleet piirteet ja niiden arvot (B).

| Variables in the Equation |                   |         |        |        |      |        |            |
|---------------------------|-------------------|---------|--------|--------|------|--------|------------|
|                           | B                 | S.E.    | Wald   | df     | Sig. | Exp(B) |            |
| Step 11                   | <b>FP_supis90</b> | ,248    | ,073   | 11,710 | 1    | ,001   | 1,282      |
|                           | <b>h32</b>        | ,081    | ,023   | 12,435 | 1    | ,000   | 1,084      |
|                           | <b>hstx5</b>      | -,654   | ,252   | 6,759  | 1    | ,009   | ,520       |
|                           | <b>isxt1</b>      | -2,146  | ,483   | 19,766 | 1    | ,000   | ,117       |
|                           | <b>iasm90</b>     | -25,794 | 7,455  | 11,972 | 1    | ,001   | ,000       |
|                           | <b>hcon135</b>    | ,695    | ,166   | 17,447 | 1    | ,000   | 2,005      |
|                           | <b>icon0</b>      | -4,821  | 2,484  | 3,767  | 1    | ,052   | ,008       |
|                           | <b>ient0</b>      | 9,235   | 3,317  | 7,751  | 1    | ,005   | 10252,876  |
|                           | <b>hhom135</b>    | 12,140  | 5,049  | 5,781  | 1    | ,016   | 187183,350 |
|                           | <b>Constant</b>   | -20,968 | 10,047 | 4,356  | 1    | ,037   | ,000       |

Piirteet ovat yhtä lukuun ottamatta tekstuuripiirteitä (katso 3.3), jotka perustuvat harmaasävyarvojen vierekkäisten esiintymien määrän perusteella määritettyyn yhteneväisyysmatriisiin (Tokola, ym. 1998, 80). FP\_supis90 on kaikkien (ainoiden ja ensimmäisten kaikujen) yli 90 prosentin korkeudella (korkeimmasta pisteestä) sijaitsevien pisteiden suhde kaikkiin yli 2 metrin korkeudella sijaitseviin pisteisiin.

Taulukosta 2 nähdään myös piirteiden tilastollinen merkitys mallissa (Sig.). Jos Sig-arvo on alle 0,05, se tarkoittaa piirteen olevan tässä mallissa tilastollisesti merkitsevä. Mallin piirteistä vain yksi ylittää tämän arvon, icon0 saa arvon 0,052. Muuttujat muodostavat yhdessä myös tilastollisesti merkittävän mallin (Taulukko 3), Sig. < 0,05.

Taulukko 3 Mallin tilastollinen merkitsevyys.

| Omnibus Tests of Model Coefficients |       |            |    |      |
|-------------------------------------|-------|------------|----|------|
|                                     |       | Chi-square | df | Sig. |
| Step 11                             | Step  | 4,127      | 1  | ,042 |
|                                     | Block | 114,824    | 9  | ,000 |
|                                     | Model | 114,824    | 9  | ,000 |

## 5.2. Mallin hyvyys

Mallin hyvyyttä arvioidaan Taulukossa 4 (myös liite 1) kahdella likelihood-arvoa hyödyntävällä testillä: Cox & Snell  $R^2$  ja Nagelkerken  $R^2$ , joilla arvioidaan mallin selitystasoa. Cox & Snell ei kuitenkaan saavuta maksimiarvoa 1, jolla täydellinen malli selittäisi havaitun todellisuuden. Nagelkerkenin mittaa on sen sijaan kehitelty niin, että se voi teoreettisesti saavuttaa maksimiarvon 1. Sen tuottama arvo kertoo suoraan, minkä osuuden havaitusta malli pystyy selittämään. (Metsämuuronen 2005, 696.)

Taulukko 4 Selitystaso.

| Step | -2 Log likelihood | Cox & Snell R Square | Nagelkerke R Square |
|------|-------------------|----------------------|---------------------|
| 11   | 139,943           | ,394                 | <b>,587</b>         |

Kuten yllä olevasta taulukosta 4 nähdään, tässä tutkimuksessa tehdyssä mallissa selitystaso on 0,587, joka merkitsee sitä, että malli selittää 59 prosenttia selitettävän muuttujan (hakkuutarve) vaihtelusta malliin tulevalla yhdeksällä piirteellä.

Taulukko 5 Yhteensopivuustesti.

| Step | Chi-square | df | Sig.        |
|------|------------|----|-------------|
| 11   | 4,558      | 8  | <b>,804</b> |

Taulukko 6 Ristitulosuhde.

|         |    | harvennustarve = 0 |          | harvennustarve = 1 |          | Total |
|---------|----|--------------------|----------|--------------------|----------|-------|
|         |    | Observed           | Expected | Observed           | Expected |       |
| Step 11 | 1  | 19                 | 20,177   | 4                  | 2,823    | 23    |
|         | 2  | 18                 | 15,094   | 5                  | 7,906    | 23    |
|         | 3  | 7                  | 9,501    | 16                 | 13,499   | 23    |
|         | 4  | 5                  | 5,560    | 18                 | 17,440   | 23    |
|         | 5  | 4                  | 3,376    | 19                 | 19,624   | 23    |
|         | 6  | 2                  | 1,407    | 21                 | 21,593   | 23    |
|         | 7  | 1                  | ,533     | 22                 | 22,467   | 23    |
|         | 8  | 0                  | ,247     | 23                 | 22,753   | 23    |
|         | 9  | 0                  | ,094     | 23                 | 22,906   | 23    |
|         | 10 | 0                  | ,009     | 22                 | 21,991   | 22    |

Mallin yhteensopivuutta aineistoon testataan logistisessa regressioanalyysissä Hosmerin & Lemeshowin testillä (Taulukot 5 ja 6, sekä Liite 2). Se mittaa kuinka hyvin arvot luokittelevat oikeisiin ryhmiin. Tilastollisessa päätelyssä khiin neliö -testin p-arvon (Sig.) tulisi olla suurempi kuin 0,05, jotta malli voitaisiin hyväksyä. Tutkimuksen mallissa

khiin neliö -testin p-arvo on suuri, 0,804, joten voidaan todeta mallin sopivan aineistoon erittäin hyvin. (Yli-Kojola 2005, 99; Metsämuuronen, 2005,704.)

Testi perustuu ryhmiteltyyn aineistoon (Taulukko 6 ja Liite 2). Havainnot järjestetään ennustearvon mukaiseen suuruusjärjestykseen ja jaetaan kymmeneen ryhmään. Nämä ryhmät jaetaan edelleen kahteen ryhmään, jolloin saadaan 2 x 10 kokoinen taulukko. Testi testaa todennäköisyyksiä näissä soluissa. (Metsämuuronen 2005, 704.)

Ennustearvot on laskettu perustuen oletukseen, että selittävien muuttujien ja selitettävän muuttujan logit-muunnoksen eli tapahtumistodennäköisyyden muunnoksen välillä on lineaarinen yhteys. Mikäli havainto on määritetty alun perin luokkaan 0, ei hakkuutarvetta, järjestetään ennustearvot suurimmasta (todennäköisyys pienempi tai yhtä suuri kuin 0,1) pienimpään (todennäköisyys 1,0). Näin saatu luokkamuuuttuja taulukoidaan ristiin vastemuuttujan (hakkuutarve/ei hakkuutarvetta) kanssa. Ja mikäli havainto on alun perin sijoittunut luokkaan 1, hakkuutarve, järjestetään arvot vastaavasti pienimmästä suurimpaan (todennäköisyydet 1,0–0,1) ja ristiintaulukoidaan edelleen vastemuuttujan kanssa. Khiin neliö -testi vertailee alkuperäisiä havaintoja ennustettuihin arvoihin lineaarisen mallin avulla. (Yli-Kojola, 2005, 17–18; Metsämuuronen 2005, 704.)

## 6 TULOSTEN TARKASTELU JA JOHTOPÄÄTÖKSET

Tämän tutkimuksen tarkoituksena oli selvittää voidaanko harvapulssisella laserpisteaineistolla (0,8 pulssia/m<sup>2</sup>) luotettavasti määrittää hakkuutoimenpidetarve nuorissa ja varttuneissa kasvatusmetsiköissä sekä uudistuskypsissä metsissä. Tutkimuksessa oli mukana yhteensä 229 koealaa. Koealoista suurin osa oli ensiharvennus- ja harvennuskohteita, vain kolmasosa sijoittui uudistuskypsille alueille. Mukana olivat sekä kivennäismaat että turvekankaat, ja metsätyypit vaihtelivat lehtomaisesta kankaasta kuivaan kankaaseen tai vastaaviin soihin.

Tarkasteltaessa toimenpidetarpeen luokittumista, voidaan todeta luokituksen onnistuneen erittäin hyvin (89,1 prosenttia). Parhaiten luokitui hakkuutarve (94,2 prosenttia). Hieman huonommin luokitui, ei hakkuutarvetta (73,2 prosenttia), joskin luokitus on silti kohtuullisen hyvä. On paljon tärkeämpää tietää, missä tarvitaan hakkuutoimenpiteitä, kuin kartoittaa alueita, joissa ei tarvita minkäänlaisia toimenpiteitä seuraavaan 10 vuoteen. Keskittyminen kohteisiin, jotka tarvitsevat toimenpiteitä eniten, parantaa kustannustehokkuutta metsien hakkuissa.

Jos aikaa olisi tutkimuksen puitteissa ollut enemmän, olisin seuraavaksi lähtenyt selvittämään tarkemmin olisiko väärinluokittuneilla kohteilla ollut joitain yhteisiä ominaisuuksia, esimerkiksi olisiko ennustearvo voinut sijoittua lähelle 0,5. Tämä selittäisi sen, että väärinluokittuneet olisivat rajatapauksia, joissa hakkuun ajankohta lähestyy, mutta ei ole vielä tarpeellinen.

Mallin hyvyyden arvioinnissa mallissa olevat muuttujat selittivät vain 58,7 prosenttia toimenpidetarpeen vaihtelusta. Loput, hieman yli 40 prosenttia ovat satunnaista eri syistä johtuvaa vaihtelua. Maanpinnan muoto ja metsätyyppi saattavat vaikuttaa laserpisteosumien sijaintiin. Suurin syy on kuitenkin luultavasti puulajikohtainen vaihtelu. Malli olisikin pitänyt ehkä jakaa kolmeen eri ositteeseen (mänty, kuusi, lehtipuu) puulajin perusteella.

Tämän tutkimuksen tuloksia ei ole testattu muualla kuin Evon opetusmetsässä, jossa aineistoa on analysoitu löydettyjen piirteiden perusteella laajemmin. Aineisto jaettiin puoliksi, jolloin malli tehtiin tutkimuksessa aiemmin esitetyillä yhdeksällä muuttujalla + vakiolla osalle aineistoa ja testattiin toisella osalla. Tulokset olivat samansuuntaisia kuin tässä tutkimuksessa esitetyt tulokset.

Selittävinä muuttujina olisi voinut testata myös metsäsuunnitelman tietoja, vaikka ne eivät olisikaan valikoituneet lopullisiksi selittäjiksi. Kehitysluokan ja toimenpidetarpeen luokitusta voitaisiin puolestaan tehdä laskennallisesti puuston järeys- ja tiheystietojen avulla ja testata tuloksia tutkimuksen mallin muuttujilla. Residuaalien osuutta eikä korrelaatioita tarkasteltu näissä tuloksissa. Ne ovat näkyvissä kuitenkin liitteessä 4.

Hakkuutoimenpidetarpeen määrittelyssä, mittaustulosten kanssa tapahtuva silmämääräinen arviointi saattaa olla luotettavampi kuin pelkkä mittaustulosten kanssa tapahtuva toimenpidetarpeen määrittely. Arviointi riippuu kuitenkin huomattavasti myös määrittelijästä, joten maastomääritys ei ole täysin ongelmaton. Tämän tutkimuksen ja mahdollisten jatkotutkimusten perusteella voitaisiin kehittää automaattinen, tulkitsijasta riippumaton menetelmä hakkuutoimenpidetarpeen määrittämiseen. Uskon, että myös toimenpiteen kiireellisyys saataisiin määritettyä käyttämällä multinominaalista logistista regressioanalyysiä, jossa selitettävä voi saada useampia arvoja.

Hakkuutoimenpidetarvetta voisi analysoida esimerkiksi neliasteisena muuttujana, hakkuuaste, jolloin muuttuja saisi arvon 1, 5, 10 tai 20 hakkuun kiireellisyyden mukaan. Muuttujan arvo 1 tarkoittaisi toimenpiteen olevan kiireellinen, muuttujan arvo 5 arvioisi toimenpiteen 1-5 vuoden päähän, muuttujan arvo 10 arvioisi toimenpiteen 5-10 vuoden päähän ja muuttujan arvo 20 tarkoittaisi, ettei toimenpidettä koettu tarpeelliseksi. Hakkuuaste voidaan ymmärtää ajallisena muuttujana, jolloin arvot merkitsevät kuinka monen vuoden kuluessa seuraava harvennus tai hakkuutoimenpide on tarpeellinen.

## 7 LOPUKSI

Tutkimuksen tuloksista päätellen voidaan todeta, että laserpisteaineiston avulla voidaan määrittää hakkuutarve erittäin hyvin. Kuviotasolle laskettaessa tulokset olisivat voineet olla vielä parempia, koska kuviotasolla koealakohtaiset tulokset keskiarvoistuvat.

Regressiomallien ongelma on usein se, että ne ovat alueellisesti sidottuja. Ne toimivat täydellisesti vain alueella, jolla malli on luotu. Eri alueiden metsiköt ja puustot poikkeavat toisistaan valtavasti. Tätä varten onkin pyritty luomaan erilaisia kasvutyyppeihin tai kehitysluokkiin perustuvia malleja (Naasset, 2004).

Mallin avulla toimenpidetarve voitaisiin yleistää suuremmalle alueelle, esimerkiksi kuvioille. Olisi mielenkiintoista laskea mallin piirteet esimerkiksi koko Evon opetusmetsään, johtaa hakkuutarve kuvioille ja vertailla niitä metsäsuunnitelman kuviotietoihin ja hakkuusuunnitteisiin. Tutkimustani ja sen tuloksia voisi soveltaa myös Metsäkeskusten uuteen, laserkeilauksella tuotettuun, yksityismetsien metsävaratietojärjestelmään.

Tekstuuripiirteitä ei laserkeilauksessa ole tutkittu kovinkaan paljon, vaikka ilmakuvista tutkittua tietoa onkin paljon. Taimikoiden hoitotarvetta ja niiden kiireellisyyttä ilmakuvista lasketujen tekstuuripiirteiden avulla ovat tutkineet esimerkiksi Packalén & Maltamo 2006 ja 2007 sekä Tuomola 2007. Laserpisteaineistosta lasketut kuvapiirteet voisivat tuoda uutta tietoa myös esimerkiksi taimikkoalueista ja niiden hoitotarpeista, joista ei tällä hetkellä saada kovinkaan tarkkoja tuloksia.

Opinnäytetyölleni asettama tavoite täyttyi, ja olen tyytyväinen myös oppimisprosessiin. Tämän tutkimuksen puitteissa opin paljon uutta, mielenkiintoista ja ajankohtaista tietoa sekä laserkeilauksesta, matemaattisista malleista että tutkimuksen teosta. Haluan kiittää työni ohjaajia Risto Viitalaa sekä Jukka Mustosta, joiden antamat neuvot ja tuki olivat erittäin merkitseviä tälle tutkimukselle. Kiitos myös Metsämiesten Säätiölle, joka mahdollisti keskittymiseni tutkimuksen tekoon.



## LÄHTEET

- Haapanen, R. 2010. Piirteiden irrotus ja valinta. Lasertekniikka-opintojakson verkkoaineisto. Hämeen ammattikorkeakoulu, Moodle2. Viitattu 1.12.2010. <https://moodle2.hamk.fi/>
- Haralick, R.M., K. Shanmugam, and I. Dinstein 1973. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*. 3(6):1973, 610–621.
- Haralick, R.M. 1979. Statistical and structural approaches to texture. *Proceedings of the IEEE*. 67(5):1979, 786–804.
- Heikkilä, J. 2004. Laserkeilaus yksityismetsien inventoinnissa. Sovellusesitykset 2009 -esityksestä lainattu kuva. Esityksen tekijä: Heikkilä, J. 2009. Viitattu 6.1.2011. <http://www.maanmittauslaitos.fi/sites/default/files/Laserkeilaus%20yksityismetsien%20inventoinnissa.pdf>
- Hynynen, J., Valkonen S. & Rantala, S. 2005. Tuottava metsänkasvatus. Metsäkustannus Oy. Helsinki: Metsäntutkimuslaitos
- Hyyppä, J., Holopainen, M., Vastaranta, M. & Puttonen E. 2009. Yksittäisten puiden mittaus ja muutosten seuranta laserkeilauksella. *Metsätieteen aikakauskirja*. 4:2009, 361–365.
- Hyyppä, J. n.d. Laserkeilaimenkäyttö puustotunnusten mittaamisessa. Remote sensing for companies. Geodeettinen laitos. Viitattu 11.1.2011. [http://www.fgi.fi/osastot/projektisivut/kk\\_www\\_portaali/rswww/lasercase1.html](http://www.fgi.fi/osastot/projektisivut/kk_www_portaali/rswww/lasercase1.html)
- Hyyppä, J. & Inkinen, M., 1999. Detecting and estimating attributes for single trees using laser scanner. *The Photogrammetric Journal of Finland*, 16:1999, 27–42.
- Hämeen ammatillisen korkeakoulutuksen metsäsuunnitelma 2006–2015. Metsähallitus, Metsätalous. Viitattu 10.1.2011.
- Komulainen, A. 2009. Varkauden laserkeilausaineistosta laaditun prosenttimallin käytettävyys Evolla. Hämeen ammattikorkeakoulu. Opinnäytetyö.
- Lindberg, A. 2009. Laserpisteaineiston hyödyntäminen manuaalisessa ennakkokuvioinnissa. Hämeen ammattikorkeakoulu. Opinnäytetyö.
- Mattila, M. 2009. Logistinen regressio. Menetelmäopetuksen tietovaranto. KvantiMOT oppimisympäristö. Viitattu 5.1.2011. <http://www.fsd.uta.fi/menetelmaopetus/logregressio/logistinen.html>

- Metsämuuronen, J. 2005. Tutkimuksen tekemisen perusteet ihmistieteissä. 3.laitos. International Methelp Ky. Jyväskylä: Gummerruksen kirjapaino Oy.
- Naasset, E. 2004. Practical large-scale forest inventory using a small footprint airborne scanning laser. *Scandinavian Journal of Forest Research* 19: 164–179.
- Nevanlinna, A. 2002. Regressioanalyysi. Viitattu 26.1.2011.  
<http://www.helsinki.fi/atk/tilasto/Spssjatko/regressio/regressio.html>
- Packalén, P. & Maltamo, M. 2006. Predicting the plot volume by tree species using airborne laser scanning and aerial photographs. *Forest Science* 56:2006, 611–622.
- Packalen, 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* 109:2007, 328–341.
- Raunio, E. 3.1.2011. mts. Vastaanottaja Anna Heikkilä. [sähköpostiviesti]. Viitattu 10.1.2011.
- Ruuskanen, S. 2010. Ilmasta käsin suoritettavan laserkeilaushankkeen prosessikuvaus konsulttiyrityksessä. *Metropolia ammattikorkeakoulu. Insinööriyö.*
- Suvanto, A., Maltamo, M., Packalén, P. & Kangas, J. 2005. Kuviokohtaisten puustotunnusten ennustaminen laserkeilauksella. *Metsätieteen aikakauskirja*. 4:2005, 413–428.
- Tokola, T., Hyppänen, H., Miina, S., Vesa, L. & Anttila P. 1998. Metsän kaukokartoitus. *Silva Carelica* 32. Joensuu: Metsätieteellinen tiedekunta.
- Tuomola, T. 2007. Numeeristen ilmakuvien käyttö havupuutaimikoiden perkaustarpeen määrittämisessä. Helsingin yliopisto. Maatalousmetsätieteellinen tiedekunta. Metsätieteiden laitos. Pro gradu -tutkielma.
- Utterä, J., Hiltunen, J., Rissanen, P., Anttila, P. & Hyvänen P. 2002. Uudet kuvioittaisen arvioinnin menetelmät – Arvio soveltuvuudetsta yksityismaiden metsäsuunnitteluun. *Metsätieteen aikakauskirja* 3:2002, 523–531.
- Vastaranta, M., Holopainen, M., Xiaowei, Y., Hyypä, H., Hyypä, J. & Viitala, R. 2010. Determination of stand first-thinning maturity using airborne laser scanning. *Silvilaser* 2010.
- Vauhkonen, J., Tokola, T., Packalén, P. & Maltamo, M., 2009. Identification of Scandinavian Commercial Species of Individual Trees from Airborne Laser Scanning Data Using Alpha Shape Metrics. *Forest Science*, 55:2009, 37–47.

Viitala, R. & Tuominen, S. 21.1.2011. Rasteripiirteiden selitykset. Vastaanottaja Anna Heikkilä. [sähköpostiviesti]. Viitattu 24.1.2011.

Yli-Kojola, H. 2005. Metsikkö- ja puutuhojen ennustemallit. Metsäntutkimuslaitoksen tiedonantoja 948. Helsinki: Metsäntutkimuslaitos.

## HAVAINTOJEN LUOKITTELU

Classification Table<sup>a</sup>

| Observed           |                |   | Predicted      |     | Percentage<br>Correct |
|--------------------|----------------|---|----------------|-----|-----------------------|
|                    |                |   | harvennustarve |     |                       |
|                    |                |   | 0              | 1   |                       |
| Step 1             | harvennustarve | 0 | 23             | 33  | 41,1                  |
|                    |                | 1 | 17             | 156 | 90,2                  |
| Overall Percentage |                |   |                |     | 78,2                  |
| Step 2             | harvennustarve | 0 | 26             | 30  | 46,4                  |
|                    |                | 1 | 16             | 157 | 90,8                  |
| Overall Percentage |                |   |                |     | 79,9                  |
| Step 3             | harvennustarve | 0 | 32             | 24  | 57,1                  |
|                    |                | 1 | 15             | 158 | 91,3                  |
| Overall Percentage |                |   |                |     | 83,0                  |
| Step 4             | harvennustarve | 0 | 31             | 25  | 55,4                  |
|                    |                | 1 | 12             | 161 | 93,1                  |
| Overall Percentage |                |   |                |     | 83,8                  |
| Step 5             | harvennustarve | 0 | 33             | 23  | 58,9                  |
|                    |                | 1 | 12             | 161 | 93,1                  |
| Overall Percentage |                |   |                |     | 84,7                  |
| Step 6             | harvennustarve | 0 | 34             | 22  | 60,7                  |
|                    |                | 1 | 11             | 162 | 93,6                  |
| Overall Percentage |                |   |                |     | 85,6                  |
| Step 7             | harvennustarve | 0 | 34             | 22  | 60,7                  |
|                    |                | 1 | 11             | 162 | 93,6                  |
| Overall Percentage |                |   |                |     | 85,6                  |
| Step 8             | harvennustarve | 0 | 33             | 23  | 58,9                  |
|                    |                | 1 | 13             | 160 | 92,5                  |
| Overall Percentage |                |   |                |     | 84,3                  |
| Step 9             | harvennustarve | 0 | 33             | 23  | 58,9                  |
|                    |                | 1 | 12             | 161 | 93,1                  |
| Overall Percentage |                |   |                |     | 84,7                  |
| Step 10            | harvennustarve | 0 | 39             | 17  | 69,6                  |
|                    |                | 1 | 9              | 164 | 94,8                  |
| Overall Percentage |                |   |                |     | 88,6                  |
| Step 11            | harvennustarve | 0 | 41             | 15  | 73,2                  |
|                    |                | 1 | 10             | 163 | 94,2                  |
| Overall Percentage |                |   |                |     | 89,1                  |

a. The cut value is ,500

## MALLIN SELITYSASTE JA YHTEENSOPIVUUS

Model Summary

| Step | -2 Log likelihood    | Cox & Snell R Square | Nagelkerke R Square |
|------|----------------------|----------------------|---------------------|
| 1    | 195,083 <sup>a</sup> | ,229                 | ,342                |
| 2    | 189,517 <sup>a</sup> | ,248                 | ,369                |
| 3    | 180,591 <sup>a</sup> | ,277                 | ,412                |
| 4    | 169,240 <sup>a</sup> | ,312                 | ,464                |
| 5    | 162,447 <sup>a</sup> | ,332                 | ,494                |
| 6    | 157,568 <sup>b</sup> | ,346                 | ,515                |
| 7    | 152,018 <sup>b</sup> | ,362                 | ,539                |
| 8    | 153,852 <sup>b</sup> | ,356                 | ,531                |
| 9    | 149,270 <sup>b</sup> | ,369                 | ,550                |
| 10   | 144,070 <sup>b</sup> | ,383                 | ,571                |
| 11   | 139,943 <sup>b</sup> | ,394                 | ,587                |

a. Estimation terminated at iteration number 6 because parameter estimates changed by less than ,001.

b. Estimation terminated at iteration number 7 because parameter estimates changed by less than ,001.

Hosmer and Lemeshow Test

| Step | Chi-square | df | Sig. |
|------|------------|----|------|
| 1    | 6,942      | 8  | ,543 |
| 2    | 1,648      | 8  | ,990 |
| 3    | 5,643      | 8  | ,687 |
| 4    | 7,188      | 8  | ,516 |
| 5    | 2,205      | 8  | ,974 |
| 6    | 3,921      | 8  | ,864 |
| 7    | 2,527      | 8  | ,960 |
| 8    | 2,188      | 8  | ,975 |
| 9    | 2,498      | 8  | ,962 |
| 10   | 5,192      | 8  | ,737 |
| 11   | 4,558      | 8  | ,804 |

Contingency Table for Hosmer and Lemeshow Test

|        |    | harvennustarve = 0 |          | harvennustarve = 1 |          | Total |
|--------|----|--------------------|----------|--------------------|----------|-------|
|        |    | Observed           | Expected | Observed           | Expected |       |
| Step 1 | 1  | 13                 | 14,555   | 10                 | 8,445    | 23    |
|        | 2  | 13                 | 12,316   | 10                 | 10,684   | 23    |
|        | 3  | 12                 | 10,018   | 12                 | 13,982   | 24    |
|        | 4  | 6                  | 6,921    | 17                 | 16,079   | 23    |
|        | 5  | 7                  | 4,881    | 16                 | 18,119   | 23    |
|        | 6  | 2                  | 3,415    | 21                 | 19,585   | 23    |
|        | 7  | 0                  | 2,077    | 23                 | 20,923   | 23    |
|        | 8  | 2                  | 1,055    | 21                 | 21,945   | 23    |
|        | 9  | 1                  | ,568     | 22                 | 22,432   | 23    |
|        | 10 | 0                  | ,194     | 21                 | 20,806   | 21    |
| Step 2 | 1  | 15                 | 15,553   | 8                  | 7,447    | 23    |
|        | 2  | 13                 | 12,061   | 10                 | 10,939   | 23    |
|        | 3  | 9                  | 9,610    | 14                 | 13,390   | 23    |
|        | 4  | 7                  | 7,114    | 16                 | 15,886   | 23    |
|        | 5  | 5                  | 4,950    | 18                 | 18,050   | 23    |
|        | 6  | 4                  | 3,268    | 19                 | 19,732   | 23    |
|        | 7  | 1                  | 1,891    | 22                 | 21,109   | 23    |
|        | 8  | 1                  | ,905     | 22                 | 22,095   | 23    |
|        | 9  | 1                  | ,489     | 22                 | 22,511   | 23    |
|        | 10 | 0                  | ,158     | 22                 | 21,842   | 22    |
| Step 3 | 1  | 17                 | 16,321   | 6                  | 6,679    | 23    |
|        | 2  | 15                 | 12,778   | 8                  | 10,222   | 23    |
|        | 3  | 8                  | 9,684    | 15                 | 13,316   | 23    |
|        | 4  | 5                  | 6,703    | 18                 | 16,297   | 23    |
|        | 5  | 5                  | 4,976    | 18                 | 18,024   | 23    |
|        | 6  | 2                  | 2,947    | 21                 | 20,053   | 23    |
|        | 7  | 2                  | 1,447    | 21                 | 21,553   | 23    |
|        | 8  | 2                  | ,694     | 21                 | 22,306   | 23    |
|        | 9  | 0                  | ,341     | 23                 | 22,659   | 23    |
|        | 10 | 0                  | ,107     | 22                 | 21,893   | 22    |
| Step 4 | 1  | 16                 | 18,146   | 7                  | 4,854    | 23    |
|        | 2  | 17                 | 12,983   | 6                  | 10,017   | 23    |
|        | 3  | 7                  | 9,334    | 16                 | 13,666   | 23    |
|        | 4  | 8                  | 6,766    | 15                 | 16,234   | 23    |
|        | 5  | 4                  | 4,313    | 19                 | 18,687   | 23    |
|        | 6  | 1                  | 2,162    | 22                 | 20,838   | 23    |
|        | 7  | 2                  | 1,206    | 21                 | 21,794   | 23    |
|        | 8  | 1                  | ,683     | 22                 | 22,317   | 23    |
|        | 9  | 0                  | ,298     | 23                 | 22,702   | 23    |

Laserkeilauksen hyödyntäminen hakkuutarpeen määrittämisessä

|        |    |    |        |    |        |    |
|--------|----|----|--------|----|--------|----|
|        | 10 | 0  | ,109   | 22 | 21,891 | 22 |
| Step 5 | 1  | 19 | 18,674 | 4  | 4,326  | 23 |
|        | 2  | 15 | 13,681 | 8  | 9,319  | 23 |
|        | 3  | 7  | 9,162  | 16 | 13,838 | 23 |
|        | 4  | 6  | 6,209  | 17 | 16,791 | 23 |
|        | 5  | 5  | 4,243  | 18 | 18,757 | 23 |
|        | 6  | 2  | 2,285  | 21 | 20,715 | 23 |
|        | 7  | 1  | ,985   | 22 | 22,015 | 23 |
|        | 8  | 1  | ,494   | 22 | 22,506 | 23 |
|        | 9  | 0  | ,194   | 23 | 22,806 | 23 |
|        | 10 | 0  | ,072   | 22 | 21,928 | 22 |
| Step 6 | 1  | 19 | 18,730 | 4  | 4,270  | 23 |
|        | 2  | 16 | 14,110 | 7  | 8,890  | 23 |
|        | 3  | 8  | 9,459  | 15 | 13,541 | 23 |
|        | 4  | 6  | 6,117  | 17 | 16,883 | 23 |
|        | 5  | 4  | 4,041  | 19 | 18,959 | 23 |
|        | 6  | 1  | 2,128  | 22 | 20,872 | 23 |
|        | 7  | 2  | ,848   | 21 | 22,152 | 23 |
|        | 8  | 0  | ,369   | 23 | 22,631 | 23 |
|        | 9  | 0  | ,155   | 23 | 22,845 | 23 |
|        | 10 | 0  | ,043   | 22 | 21,957 | 22 |
| Step 7 | 1  | 19 | 19,249 | 4  | 3,751  | 23 |
|        | 2  | 16 | 14,173 | 7  | 8,827  | 23 |
|        | 3  | 9  | 9,293  | 14 | 13,707 | 23 |
|        | 4  | 7  | 6,211  | 16 | 16,789 | 23 |
|        | 5  | 2  | 3,986  | 21 | 19,014 | 23 |
|        | 6  | 2  | 1,986  | 21 | 21,014 | 23 |
|        | 7  | 1  | ,697   | 22 | 22,303 | 23 |
|        | 8  | 0  | ,272   | 23 | 22,728 | 23 |
|        | 9  | 0  | ,107   | 23 | 22,893 | 23 |
|        | 10 | 0  | ,026   | 22 | 21,974 | 22 |
| Step 8 | 1  | 18 | 19,362 | 5  | 3,638  | 23 |
|        | 2  | 15 | 13,731 | 8  | 9,269  | 23 |
|        | 3  | 10 | 9,266  | 13 | 13,734 | 23 |
|        | 4  | 5  | 6,341  | 18 | 16,659 | 23 |
|        | 5  | 5  | 4,000  | 18 | 19,000 | 23 |
|        | 6  | 2  | 2,064  | 21 | 20,936 | 23 |
|        | 7  | 1  | ,796   | 22 | 22,204 | 23 |
|        | 8  | 0  | ,293   | 23 | 22,707 | 23 |
|        | 9  | 0  | ,119   | 23 | 22,881 | 23 |
|        | 10 | 0  | ,027   | 22 | 21,973 | 22 |
| Step 9 | 1  | 19 | 19,449 | 4  | 3,551  | 23 |
|        | 2  | 14 | 14,155 | 9  | 8,845  | 23 |
|        | 3  | 11 | 9,415  | 12 | 13,585 | 23 |

Laserkeilauksen hyödyntäminen hakkuutarpeen määrittämisessä

|         |    |    |        |    |        |    |
|---------|----|----|--------|----|--------|----|
|         | 4  | 4  | 6,243  | 19 | 16,757 | 23 |
|         | 5  | 5  | 4,115  | 18 | 18,885 | 23 |
|         | 6  | 2  | 1,737  | 21 | 21,263 | 23 |
|         | 7  | 1  | ,589   | 22 | 22,411 | 23 |
|         | 8  | 0  | ,193   | 23 | 22,807 | 23 |
|         | 9  | 0  | ,091   | 23 | 22,909 | 23 |
|         | 10 | 0  | ,014   | 22 | 21,986 | 22 |
| Step 10 | 1  | 19 | 19,648 | 4  | 3,352  | 23 |
|         | 2  | 18 | 14,963 | 5  | 8,037  | 23 |
|         | 3  | 7  | 9,382  | 16 | 13,618 | 23 |
|         | 4  | 4  | 5,951  | 19 | 17,049 | 23 |
|         | 5  | 5  | 3,705  | 18 | 19,295 | 23 |
|         | 6  | 2  | 1,526  | 21 | 21,474 | 23 |
|         | 7  | 1  | ,536   | 22 | 22,464 | 23 |
|         | 8  | 0  | ,203   | 23 | 22,797 | 23 |
|         | 9  | 0  | ,077   | 23 | 22,923 | 23 |
|         | 10 | 0  | ,008   | 22 | 21,992 | 22 |
| Step 11 | 1  | 19 | 20,177 | 4  | 2,823  | 23 |
|         | 2  | 18 | 15,094 | 5  | 7,906  | 23 |
|         | 3  | 7  | 9,501  | 16 | 13,499 | 23 |
|         | 4  | 5  | 5,560  | 18 | 17,440 | 23 |
|         | 5  | 4  | 3,376  | 19 | 19,624 | 23 |
|         | 6  | 2  | 1,407  | 21 | 21,593 | 23 |
|         | 7  | 1  | ,533   | 22 | 22,467 | 23 |
|         | 8  | 0  | ,247   | 23 | 22,753 | 23 |
|         | 9  | 0  | ,094   | 23 | 22,906 | 23 |
|         | 10 | 0  | ,009   | 22 | 21,991 | 22 |



## LASERPIIRTEET

Variables in the Equation

|                     |            | B       | S.E.  | Wald   | df | Sig. | Exp(B)      |
|---------------------|------------|---------|-------|--------|----|------|-------------|
| Step 1 <sup>a</sup> | LP_vege    | 10,728  | 1,779 | 36,354 | 1  | ,000 | 45609,780   |
|                     | Constant   | -,694   | ,292  | 5,655  | 1  | ,017 | ,500        |
| Step 2 <sup>b</sup> | LP_vege    | 9,918   | 1,843 | 28,954 | 1  | ,000 | 20293,624   |
|                     | isxt1      | -,310   | ,135  | 5,309  | 1  | ,021 | ,733        |
|                     | Constant   | 2,301   | 1,324 | 3,020  | 1  | ,082 | 9,988       |
| Step 3 <sup>c</sup> | LP_vege    | 9,378   | 1,878 | 24,943 | 1  | ,000 | 11830,754   |
|                     | isxt1      | -,945   | ,270  | 12,279 | 1  | ,000 | ,389        |
|                     | iasm90     | -17,337 | 6,006 | 8,331  | 1  | ,004 | ,000        |
|                     | Constant   | 12,239  | 3,789 | 10,432 | 1  | ,001 | 206618,309  |
| Step 4 <sup>d</sup> | LP_vege    | 7,156   | 1,990 | 12,936 | 1  | ,000 | 1281,778    |
|                     | isxt1      | -1,266  | ,302  | 17,621 | 1  | ,000 | ,282        |
|                     | iasm90     | -20,195 | 6,283 | 10,331 | 1  | ,001 | ,000        |
|                     | hcon135    | ,166    | ,057  | 8,554  | 1  | ,003 | 1,181       |
|                     | Constant   | 14,912  | 4,024 | 13,736 | 1  | ,000 | 2993610,993 |
| Step 5 <sup>e</sup> | FP_supis90 | ,147    | ,055  | 7,196  | 1  | ,007 | 1,159       |
|                     | LP_vege    | 7,090   | 1,979 | 12,835 | 1  | ,000 | 1199,775    |
|                     | isxt1      | -1,415  | ,318  | 19,768 | 1  | ,000 | ,243        |
|                     | iasm90     | -22,903 | 6,547 | 12,236 | 1  | ,000 | ,000        |
|                     | hcon135    | ,225    | ,065  | 12,120 | 1  | ,000 | 1,253       |
|                     | Constant   | 2,487   | 5,829 | ,182   | 1  | ,670 | 12,026      |
| Step 6 <sup>f</sup> | FP_supis90 | ,153    | ,058  | 6,945  | 1  | ,008 | 1,165       |
|                     | LP_vege    | 6,007   | 2,110 | 8,106  | 1  | ,004 | 406,366     |
|                     | hstx5      | -,434   | ,202  | 4,604  | 1  | ,032 | ,648        |
|                     | isxt1      | -1,541  | ,341  | 20,427 | 1  | ,000 | ,214        |
|                     | iasm90     | -22,750 | 6,680 | 11,599 | 1  | ,001 | ,000        |
|                     | hcon135    | ,392    | ,111  | 12,570 | 1  | ,000 | 1,480       |
|                     | Constant   | 4,104   | 6,219 | ,435   | 1  | ,509 | 60,555      |
| Step 7 <sup>g</sup> | FP_supis90 | ,193    | ,060  | 10,379 | 1  | ,001 | 1,213       |
|                     | LP_vege    | 3,252   | 2,429 | 1,793  | 1  | ,181 | 25,851      |
|                     | h32        | ,045    | ,020  | 5,155  | 1  | ,023 | 1,046       |
|                     | hstx5      | -,671   | ,231  | 8,418  | 1  | ,004 | ,511        |
|                     | isxt1      | -1,613  | ,362  | 19,902 | 1  | ,000 | ,199        |
|                     | iasm90     | -27,191 | 7,487 | 13,191 | 1  | ,000 | ,000        |
|                     | hcon135    | ,426    | ,115  | 13,608 | 1  | ,000 | 1,531       |
|                     | Constant   | 1,398   | 5,989 | ,055   | 1  | ,815 | 4,047       |
| Step 8 <sup>g</sup> | FP_supis90 | ,207    | ,058  | 12,620 | 1  | ,000 | 1,230       |
|                     | h32        | ,057    | ,017  | 10,592 | 1  | ,001 | 1,058       |
|                     | hstx5      | -,800   | ,212  | 14,280 | 1  | ,000 | ,449        |

Laserkeilauksen hyödyntäminen hakkuutarpeen määrittämisessä

|                      |            |         |        |        |   |      |            |
|----------------------|------------|---------|--------|--------|---|------|------------|
|                      | isxt1      | -1,779  | ,349   | 26,038 | 1 | ,000 | ,169       |
|                      | iasm90     | -29,979 | 7,329  | 16,729 | 1 | ,000 | ,000       |
|                      | hcon135    | ,494    | ,108   | 20,758 | 1 | ,000 | 1,639      |
|                      | Constant   | 2,312   | 5,874  | ,155   | 1 | ,694 | 10,094     |
| Step 9 <sup>h</sup>  | FP_supis90 | ,264    | ,069   | 14,760 | 1 | ,000 | 1,302      |
|                      | h32        | ,069    | ,020   | 12,126 | 1 | ,000 | 1,071      |
|                      | hstx5      | -,745   | ,220   | 11,516 | 1 | ,001 | ,475       |
|                      | isxt1      | -1,733  | ,356   | 23,684 | 1 | ,000 | ,177       |
|                      | iasm90     | -31,061 | 7,504  | 17,134 | 1 | ,000 | ,000       |
|                      | hcon135    | ,677    | ,151   | 20,100 | 1 | ,000 | 1,967      |
|                      | hhom135    | 9,708   | 4,637  | 4,384  | 1 | ,036 | 16454,764  |
|                      | Constant   | -9,323  | 8,236  | 1,282  | 1 | ,258 | ,000       |
| Step 10 <sup>i</sup> | FP_supis90 | ,259    | ,071   | 13,326 | 1 | ,000 | 1,295      |
|                      | h32        | ,088    | ,022   | 15,617 | 1 | ,000 | 1,092      |
|                      | hstx5      | -,822   | ,233   | 12,499 | 1 | ,000 | ,440       |
|                      | isxt1      | -2,329  | ,465   | 25,087 | 1 | ,000 | ,097       |
|                      | iasm90     | -29,509 | 7,463  | 15,633 | 1 | ,000 | ,000       |
|                      | hcon135    | ,739    | ,164   | 20,210 | 1 | ,000 | 2,094      |
|                      | ient0      | 5,768   | 2,604  | 4,905  | 1 | ,027 | 319,827    |
|                      | hhom135    | 13,104  | 5,077  | 6,662  | 1 | ,010 | 490814,203 |
|                      | Constant   | -17,099 | 9,295  | 3,384  | 1 | ,066 | ,000       |
| Step 11 <sup>j</sup> | FP_supis90 | ,248    | ,073   | 11,710 | 1 | ,001 | 1,282      |
|                      | h32        | ,081    | ,023   | 12,435 | 1 | ,000 | 1,084      |
|                      | hstx5      | -,654   | ,252   | 6,759  | 1 | ,009 | ,520       |
|                      | isxt1      | -2,146  | ,483   | 19,766 | 1 | ,000 | ,117       |
|                      | iasm90     | -25,794 | 7,455  | 11,972 | 1 | ,001 | ,000       |
|                      | hcon135    | ,695    | ,166   | 17,447 | 1 | ,000 | 2,005      |
|                      | icon0      | -4,821  | 2,484  | 3,767  | 1 | ,052 | ,008       |
|                      | ient0      | 9,235   | 3,317  | 7,751  | 1 | ,005 | 10252,876  |
|                      | hhom135    | 12,140  | 5,049  | 5,781  | 1 | ,016 | 187183,350 |
|                      | Constant   | -20,968 | 10,047 | 4,356  | 1 | ,037 | ,000       |

KORRELAATIOMATRIISI JA RESIDUAALIT

Correlation Matrix

|        | Con<br>stan<br>t | LP_ve<br>ge | isxt1 | iasm9<br>0 | hcon1<br>35 | Consta<br>nt | FP_supi<br>s90 | LP_ve<br>ge | isxt1 | iasm90 | hcon1<br>35 |
|--------|------------------|-------------|-------|------------|-------------|--------------|----------------|-------------|-------|--------|-------------|
| Step 1 | Constant         | 1,00        | -,795 |            |             |              |                |             |       |        |             |
|        | LP_vege          | -,795       | 1,000 |            |             |              |                |             |       |        |             |
| Step 2 | Constant         | 1,00        | -,288 | -,974      |             |              |                |             |       |        |             |
|        | LP_vege          | -,288       | 1,000 | ,112       |             |              |                |             |       |        |             |
|        | isxt1            | -,974       | ,112  | 1,000      |             |              |                |             |       |        |             |
| Step 3 | Constant         | 1,00        | -,116 | -,980      | -,929       |              |                |             |       |        |             |
|        | LP_vege          | -,116       | 1,000 | ,062       | ,028        |              |                |             |       |        |             |
|        | isxt1            | -,980       | ,062  | 1,000      | ,850        |              |                |             |       |        |             |
|        | iasm90           | -,929       | ,028  | ,850       | 1,000       |              |                |             |       |        |             |
| Step 4 | Constant         | 1,00        | -,213 | -,972      | -,930       | ,279         |                |             |       |        |             |
|        | LP_vege          | -,213       | 1,000 | ,201       | ,098        | -,294        |                |             |       |        |             |
|        | isxt1            | -,972       | ,201  | 1,000      | ,841        | -,414        |                |             |       |        |             |
|        | iasm90           | -,930       | ,098  | ,841       | 1,000       | -,198        |                |             |       |        |             |
|        | hcon135          | ,279        | -,294 | -,414      | -,198       | 1,000        |                |             |       |        |             |
| Step 5 | Constant         |             |       |            |             | 1,000        | -,718          | -,174       | -,436 | -,458  | -,129       |
|        | FP_supis90       |             |       |            |             | -,718        | 1,000          | ,060        | -,293 | -,237  | ,400        |
|        | LP_vege          |             |       |            |             | -,174        | ,060           | 1,000       | ,154  | ,054   | -,234       |
|        | isxt1            |             |       |            |             | -,436        | -,293          | ,154        | 1,000 | ,847   | -,459       |
|        | iasm90           |             |       |            |             | -,458        | -,237          | ,054        | ,847  | 1,000  | -,244       |
|        | hcon135          |             |       |            |             | -,129        | ,400           | -,234       | -,459 | -,244  | 1,000       |

Laserkeilauksen hyödyntäminen hakkuutarpeen määrittämisessä

|      |          |  |  |  |  |       |       |       |       |       |       |
|------|----------|--|--|--|--|-------|-------|-------|-------|-------|-------|
| Step | Constant |  |  |  |  | 1,000 | -,711 | -,197 | -,449 | -,466 | ,004  |
| 6    | FP_supis |  |  |  |  | -,711 | 1,000 | ,015  | -,289 | -,216 | ,315  |
|      | 90       |  |  |  |  |       |       |       |       |       |       |
|      | LP_vege  |  |  |  |  | -,197 | ,015  | 1,000 | ,239  | ,098  | -,312 |
|      | hstx5    |  |  |  |  | -,119 | -,085 | ,200  | ,239  | ,026  | -,767 |
|      | isxt1    |  |  |  |  | -,449 | -,289 | ,239  | 1,000 | ,829  | -,465 |
|      | iasm90   |  |  |  |  | -,466 | -,216 | ,098  | ,829  | 1,000 | -,158 |
|      | hcon135  |  |  |  |  | ,004  | ,315  | -,312 | -,465 | -,158 | 1,000 |
| Step | Constant |  |  |  |  | 1,000 | -,666 | -,097 | -,412 | -,388 | -,026 |
| 7    | FP_supis |  |  |  |  | -,666 | 1,000 | -,148 | -,385 | -,352 | ,383  |
|      | 90       |  |  |  |  |       |       |       |       |       |       |
|      | LP_vege  |  |  |  |  | -,097 | -,148 | 1,000 | ,281  | ,232  | -,378 |
|      | h32      |  |  |  |  | -,136 | ,298  | -,430 | -,173 | -,335 | ,166  |
|      | hstx5    |  |  |  |  | ,009  | -,267 | ,366  | ,281  | ,168  | -,749 |
|      | isxt1    |  |  |  |  | -,412 | -,385 | ,281  | 1,000 | ,832  | -,490 |
|      | iasm90   |  |  |  |  | -,388 | -,352 | ,232  | ,832  | 1,000 | -,218 |
|      | hcon135  |  |  |  |  | -,026 | ,383  | -,378 | -,490 | -,218 | 1,000 |
| Step | Constant |  |  |  |  | 1,000 | -,679 |       | -,411 | -,387 | -,068 |
| 8    | FP_supis |  |  |  |  | -,679 | 1,000 |       | -,368 | -,334 | ,369  |
|      | 90       |  |  |  |  |       |       |       |       |       |       |
|      | h32      |  |  |  |  | -,196 | ,260  |       | -,056 | -,273 | -,004 |
|      | hstx5    |  |  |  |  | ,062  | -,254 |       | ,211  | ,095  | -,713 |
|      | isxt1    |  |  |  |  | -,411 | -,368 |       | 1,000 | ,822  | -,443 |
|      | iasm90   |  |  |  |  | -,387 | -,334 |       | ,822  | 1,000 | -,150 |
|      | hcon135  |  |  |  |  | -,068 | ,369  |       | -,443 | -,150 | 1,000 |
| Step | Constant |  |  |  |  | 1,000 | -,763 |       | -,260 | -,172 | -,494 |
| 9    | FP_supis |  |  |  |  | -,763 | 1,000 |       | -,353 | -,363 | ,556  |
|      | 90       |  |  |  |  |       |       |       |       |       |       |
|      | h32      |  |  |  |  | -,386 | ,377  |       | -,045 | -,290 | ,188  |
|      | hstx5    |  |  |  |  | ,025  | -,213 |       | ,204  | ,076  | -,494 |
|      | isxt1    |  |  |  |  | -,260 | -,353 |       | 1,000 | ,817  | -,354 |
|      | iasm90   |  |  |  |  | -,172 | -,363 |       | ,817  | 1,000 | -,191 |
|      | hcon135  |  |  |  |  | -,494 | ,556  |       | -,354 | -,191 | 1,000 |
|      | hhom135  |  |  |  |  | -,675 | ,462  |       | -,044 | -,147 | ,647  |
| Step | Constant |  |  |  |  | 1,000 | -,738 |       | ,063  | -,158 | -,492 |
| 10   | FP_supis |  |  |  |  | -,738 | 1,000 |       | -,249 | -,333 | ,484  |
|      | 90       |  |  |  |  |       |       |       |       |       |       |
|      | h32      |  |  |  |  | -,507 | ,353  |       | -,292 | -,232 | ,254  |
|      | hstx5    |  |  |  |  | ,077  | -,159 |       | ,283  | ,053  | -,537 |
|      | isxt1    |  |  |  |  | ,063  | -,249 |       | 1,000 | ,600  | -,412 |
|      | iasm90   |  |  |  |  | -,158 | -,333 |       | ,600  | 1,000 | -,167 |
|      | hcon135  |  |  |  |  | -,492 | ,484  |       | -,412 | -,167 | 1,000 |
|      | ient0    |  |  |  |  | -,382 | ,031  |       | -,658 | ,011  | ,236  |
|      | hhom135  |  |  |  |  | -,699 | ,434  |       | -,243 | -,142 | ,670  |

## Laserkeilauksen hyödyntäminen hakkuutarpeen määrittämisessä

|      |          |  |  |  |  |       |       |       |       |       |
|------|----------|--|--|--|--|-------|-------|-------|-------|-------|
| Step | Constant |  |  |  |  | 1,000 | -,743 | ,015  | -,211 | -,398 |
| 11   | FP_supis |  |  |  |  | -,743 | 1,000 | -,195 | -,274 | ,418  |
|      | 90       |  |  |  |  |       |       |       |       |       |
|      | h32      |  |  |  |  | -,510 | ,380  | -,287 | -,198 | ,230  |
|      | hstx5    |  |  |  |  | -,022 | -,104 | ,280  | ,078  | -,513 |
|      | isxt1    |  |  |  |  | ,015  | -,195 | 1,000 | ,590  | -,403 |
|      | iasm90   |  |  |  |  | -,211 | -,274 | ,590  | 1,000 | -,175 |
|      | hcon135  |  |  |  |  | -,398 | ,418  | -,403 | -,175 | 1,000 |
|      | icon0    |  |  |  |  | ,229  | ,010  | -,125 | -,195 | ,073  |
|      | ient0    |  |  |  |  | -,445 | ,049  | -,486 | ,113  | ,143  |
|      | hhom135  |  |  |  |  | -,623 | ,413  | -,237 | -,164 | ,661  |

### Casewise List<sup>b</sup>

| Case | Selected Status <sup>a</sup> | Observed       | Predicted | Predicted Group | Temporary Variable |        |
|------|------------------------------|----------------|-----------|-----------------|--------------------|--------|
|      |                              | harvennustarve |           |                 | Resid              | ZResid |
| 33   | S                            | 0**            | ,924      | 1               | -,924              | -3,496 |
| 34   | S                            | 1**            | ,158      | 0               | ,842               | 2,310  |
| 48   | S                            | 0**            | ,924      | 1               | -,924              | -3,490 |
| 88   | S                            | 0**            | ,878      | 1               | -,878              | -2,682 |
| 145  | S                            | 0**            | ,967      | 1               | -,967              | -5,375 |
| 165  | S                            | 0**            | ,897      | 1               | -,897              | -2,958 |
| 187  | S                            | 1**            | ,142      | 0               | ,858               | 2,463  |
| 198  | S                            | 0**            | ,879      | 1               | -,879              | -2,693 |

a. S = Selected, U = Unselected cases, and \*\* = Misclassified cases.

b. Cases with studentized residuals greater than 2,000 are listed.