



ITÄ-SUOMEN
YLIOPISTO

University of Eastern Finland
Luonnontieteiden ja
metsätieteiden tiedekunta
Faculty of Science and Forestry

**Laserkeilauksen käyttö metsänhoitotarpeen määrittämisessä
taimikoissa ja nuorissa kasvatusemetsiköissä**

Mikko Nivala

METSÄTIETEEN MAISTERIN TUTKIELMA

Metsäsuunnittelu ja metsäarviointi

Nivala, Mikko. 2012. Laserkeilauksen käyttö metsänhoitotarpeen määrittämisessä taimikoissa ja nuorissa kasvatusmetsäkoissa. Itä-Suomen yliopisto, luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto, metsätieteen pro gradu, erikoistumisala metsänarviointi ja metsäsuunnittelu. 65 s.

Tiivistelmä

Työn tarkoituksena on tutkia laserkeilauksen käyttämistä inventointitiedon ohella myös metsäsuunnittelun toimenpidetarpeen määrittämisessä. Työ rajattiin keskittymään hoitamattomiin ensiharvennusmetsäkoihin ja sitä nuorempiin metsäkoihin lukuun ottamatta varhaisperkauskohteita, joissa puuston keskipituus on vähemmän kuin 2 metriä. Työni tuloksena oli tarkoitus saada selville, onko mahdollista löytää hoitamattomat taimikot sekä energiapuukorjuuseen kelpaavat kohteet käyttäen laserkeilausperusteista inventointia.

Aineisto kerättiin Pohjois-Savon alueelta kesän 2009 aikana. Aineisto koostuu 104 mikrokuviosta, joista on inventointitietojen ohella määritetty hoitotoimenpide sekä ajoitus. Laserkeilausaineiston tuotti Blom Kartta Oy. Tutkimusmenetelmänä käytin diskreetteihin analyyseihin perustuvia luokittelufunktioita LDA:ta (Linear Discriminant Analysis) sekä QDA:ta (Quadratic Discriminant Analysis), joiden avulla laadin luokittelumallit käyttäen lasertunnuksia.

Tutkimuksen perusteella voidaan todeta, että laserkeilausperusteista inventointia voidaan käyttää myös operatiivisen suunnittelun työkaluna. Tutkittaessa, miten hoitamattomat nuoren metsän kunnostuskohteet sekä taimikonhoitokohteet löytyivät mallien avulla, pääsin 76,92 %:n oikeinluokittumisprosenttiin. Kappa-arvo oli 0,645. Kyseisen luokittelun osalta energiapuukohteet luokittuivat 100-prosenttisesti oikein, taimikonhoitokohteet 79,07 %:n, mutta ei kohteet alle 50 %:n tarkkuudella. Käytettäessä ainoastaan kahta luokkaa eli luokkia hoitotarve ja ei hoitotarvetta, oikeinluokittumisprosentti oli vieläkin korkeampi. Varsinaisten hoitotarvetta vaativien kohteiden korkean luokittumisprosentin perusteella voidaan sanoa, että laserkeilausperusteinen inventointi on riittävän hyvä työkalu myös operatiiviseen suunnitteluun nuorten metsien kunnostuskohteiden ja taimikonhoitokohteiden kartoittamiseksi. Lisäksi tutkin, onko mahdollista selvittää toimenpidetarpeen ajoitus. Kyseisen mallin oikeinluokittumisaste oli yli 70 % ja kappa-arvo 0,604, joten myös tämä tulos on suuntaa-antava laserkeilauksen käyttämisestä entistä laajamittaisemmin.

Tutkimuksen tulokset ovat hyvin samansuuntaiset kuin aiempien tutkimuksien tulokset.

Avainsanat: Laserkeilaus, luokittelumenetelmät, QDA, energiapuu, taimikonhoito, metsänhoitotarve ja metsäsuunnittelu

Nivala, Mikko. 2012. Using Remote Sensing to examine need for forest management in seedlings and young forest stands. University of Eastern Finland, Faculty of Science and Forestry, School of Forest Sciences, master's thesis in Forest Science specialization Forest Mensuration and Forest Planning, 65 p.

Abstract

The purpose of this study was to research the use of airborne laser scanning (ALS) as an inventory data but in addition as a decision making tool in Finnish forest planning. The work focused on the dense, untreated young forest stands and seedlings stands, excluding the youngest seedlings stands where the average height of the seedlings is less than 2 m. The main goal of this study was to examine whether it is possible to find areas where there is a need for tendling of seedling stands and fuel wood thinning stands by using ALS based inventory.

The field data was collected in the North-Savo area of Finland during the summer of 2009. The data consists of 104 micro-stands and all of these micro-stands were measured in the field. The field data also includes a subjective analysis of the need for a management type for the micro-stands, and for the timing of that management. Laser scanner data has been produced by Blom Kartta Inc. The research method was based on the analysis of discrete classification functions LDA (Linear Discriminant Analysis) and QDA (Quadratic Discriminant Analysis). The classification model was built by using ALS data.

It can be concluded that ALS could also be used as a decision-making tool for forest planning in Finland. This research shows that it is possible to find areas that need tendling of seedlings or fuel wood thinning. When using three classes in the model: fuel wood thinning, tendling of seedlings and no need for management, the result was 76.92% of the classification accuracy and a kappa value of 0.645. In addition the classification of the fuel wood thinning compartment was 100% correct, with the tendling of seedlings at 79.07%, but for those where there was no need for management the accuracy was less than 50% correct. Using only two classes: need for management and no need for management, the results were even better. As the study goal was to make sure that within the model the first two classes were as high as possible, it can be said that an ALS based inventory is a sufficiently good enough tool for operational forest planning when we need to decide a management need for young forest and seedlings' compartments. When researching the timing of these management types the model classification accuracy was more than 70%, with a kappa value of 0.604. This result also illustrates that the use of ALS could be used more comprehensively in different forest applications and in forest planning especially.

The study result is also very similar to previous studies in which ALS has been utilised as a decision-making and planning tool.

Keywords: ALS, classification methods, QDA, fuel wood, young stand management, forest management needs and forest planning

Alkusanat

Tutkimustyöni alkoi jo varsin kauan aikaa sitten keskustelusta UPM Metsällä työskennelleen Kauko Kärkkäisen kanssa laadunmittausten loppuraporttien esitystilaisuuden jälkeen jouluna 2008. Keskustelun jälkeen työ eteni sähköpostien sekä puheluiden avulla. Lopulta pro gradu -työn aihe selkeni ja tutkimuksen tekokuviot selkeytyivät siten, että keväällä 2009 aloin kirjoittamaan tutkimussuunnitelmaa. Valitettavasti tutkimussuunnitelma ei ehtinyt valmiiksi ennen kesää 2009, mutta siitä huolimatta onnistuin keräämään maastoaineiston kesän 2009 aikana. Varsinaiset analysoinnit aineistosta tapahtuivat loppuvuodesta 2009 sekä vuoden 2010 alussa. Lukukauden 2010-2011 olin kuitenkin päättänyt viettää vaihdossa, joten Indonesia kutsui ja työ jäi seisomaan reilun vuoden ajaksi. Palattuani Suomeen tutkimus vähitellen valmistui töiden ohella ja jouluna 2011 se oli jo esitysvalmis.

Paljon on ehtinyt tapahtua graduni teon aikana. Nuorelle aktiiviopiskelijalle, joka ei osannut sanoa ei eri virkatehtäville, kiirettä on riittänyt. Vuodet IFSA:n (International Forestry Students' Association) virkatehtävissä sekä erilaiset lyhyet työtehtävät veivät aikaa, mutta kasvattivat tulevaisuuden haasteisiin. Aloittaessani työni en olisi ikinä uskonut, että työn valmistuessa olisin jo naimisissa ja että perheellisäystä olisi tulossa pikapuolin.

Tutkimuksen tekopaikkana toimivat UPM-Kymmene Oyj:n metsätalousoaston toimisto Sirkkalantiellä Joensuussa sekä Itä-Suomen yliopiston luonnontieteiden ja metsätieteiden tiedekunnan atk-tilat.

Tutkimuksen ohjaajina toimivat Petteri Packalen Itä-Suomen yliopiston luonnontieteiden ja metsätieteiden tiedekunnasta sekä Kauko Kärkkäinen (nykyisin työskentelee Tornator Oy:llä) ja Janne Uuttera UPM-Kymmene Oyj:ltä. Aineiston keräämisessä avustajana toimi Piritta Pyörälä ja laseraineiston hankinnasta vastasi Blom. Tulosten analysoinnissa sekä mallin rakentamisessa avustivat tutkija (MMT) Jari Vauhkonen sekä tutkija (MMM) Inka Pippuri Itä-Suomen yliopiston luonnontieteiden ja metsätieteiden tiedekunnasta. Kiitokset metsätieteiden osastolle tutkimuksen avustamisesta sekä työskentelytilojen antamisesta. Erityiskiitokset kuuluvat UPM:lle tutkimuksen rahoittamisesta, toimistopaikan antamisesta käyttöni ja kehittävästä työharjoittelusta ammattini

kannalta. Kiitokset myös ystäville sekä vaimolleni, jotka ovat tukeneet minua työn loppuunsaattamiseksi.

Tutkimuksessa käytettävä aineisto on mahdollista saada lähettämällä sähköpostia osoitteeseen:
mikko.ifs@gmail.com

Joensuu 20. Helmikuuta 2012

Mikko Nivala

Sisällysluettelo

Tiivistelmä.....	2
Abstract.....	3
Alkusanat.....	4
Sisällysluettelo.....	6
1. Johdanto	7
1.1 Tutkimuksen tausta.....	7
1.2 Teoreettinen viitekehys.....	12
1.2.1 Taimikko ja taimikonhoito.....	12
1.2.2 Energiapuuharvennuskohde.....	14
1.2.3 Laserkeilaus.....	16
1.2.4 Lasertunnukset.....	19
1.2.5 Mikrokuvio.....	20
1.3 Tutkimuksen tavoitteet.....	20
2. Aineisto	23
2.1 Aineiston analysointi.....	26
3. Tutkimusmenetelmät.....	28
3.1 Tilastolliset luokittelumallit.....	28
3.1.1 Lineaarinen diskriminanttianalyysi (LDA).....	29
3.1.2 Neliöllinen diskriminanttianalyysi (QDA).....	30
3.2 Mallin tarkastelu.....	32
4. Tulokset.....	35
4.1 Objektiiviseen luokitteluun perustuvat mallit.....	35
4.2 Maastopohjaiseen luokitukseen pohjautuvat mallit.....	42
4.3 Ajoituksen tutkiminen.....	45
5. Diskussio.....	49
Kirjallisuus	51
LIITTEET.....	55
Lisätaulukot.....	55
Muuttujien valinnan helpottamista varten tehty ohjelma.....	58
R-ohjelman käyttöön liittyvät koodaukset.....	60

1. Johdanto

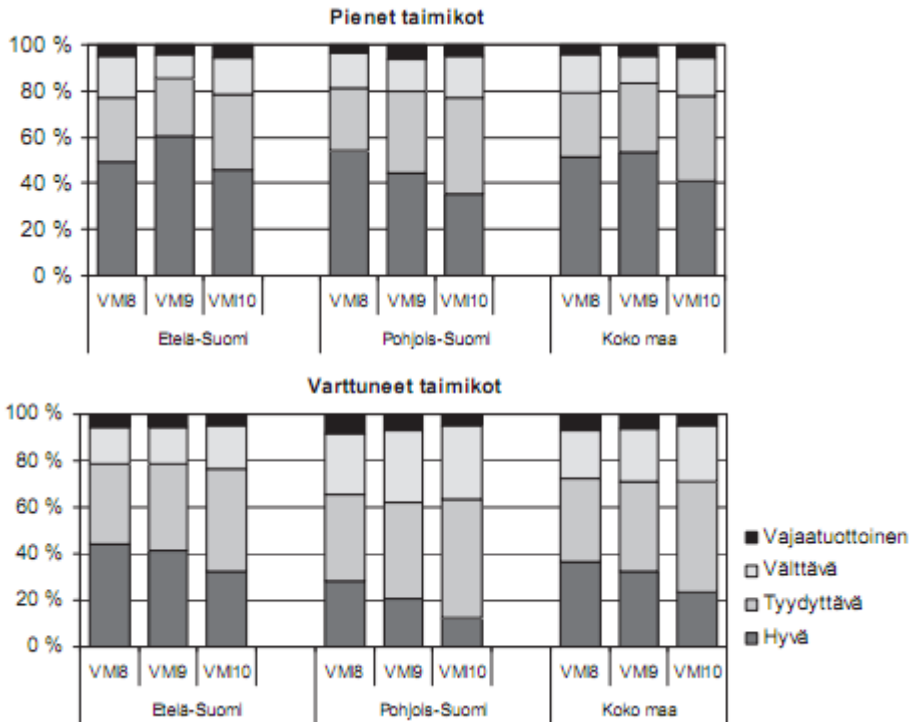
1.1 Tutkimuksen tausta

Suomessa metsäomistajakunnan muuttuessa on mahdollista, että yhä suurempi osa taimikonhoitotöistä jää tekemättä, mikä aiheuttaa metsien ylitiheyttä ja myöhemmin riukuuntumista (taulukko 1). Tulevaisuudessa on riski, että metsänomistajakunta vieraantuu omistamastaan metsästä ja itsenäisesti suoritettavat taimikonhoitotyöt jäävät tekemättä, mikäli metsänomistaja ei tee hoitosopimusta metsäpalveluyrityksen kanssa.

Taulukko 1. Metsänomistajakunnan rakenne 1999 sekä ennusteet vuosille 2010 ja 2020 (Metsätieteen aikakauskirja 1/2008, Karppinen ja Alhberg sekä eletkronisena <http://www.metla.fi/aikakauskirja/full/ff08/ff081017.pdf>)


	1999	2010	2020
<i>Keski-ikä ja ikäluokat</i>			
Keski-ikä (vuotta)	57	58	59–60
Alle 40-vuotiaat	11	9–10	8–9
40–59-vuotiaat	45	43–44	41–43
60 vuotta täyttäneet	44	48–50	53–56
<i>Sukupuoli</i>			
Naisten osuus	24	30–32	32–38
<i>Ammattiasema</i>			
Palkansaajat	30	30–32	31–35
Maa/metsätalousyrittäjät	22	13–16	5–13
Yrittäjät	6	6–7	5–8
Eläkeläiset	37	47–49	53–57
Muut	5	3–5	2–6
<i>Koulutusrakenne</i>			
Ylioppilas	15	20–21	27–28
Ei tutkintoa	45	38–39	33–36
Koulutasoinen tutkinto	29	29–30	29–31
Opistotasoinen tutkinto	17	21–23	24–27
Akateeminen tutkinto	9	10–11	12–13

Taimikoiden laatu on heikentynyt viimeisten vuosien aikana. Tämä selviää Korhosen ym. (2010) suorittamasta tutkimuksesta, jossa vertailtiin metsänuudistamisen tilaa Suomessa VMI (Valtion Metsien Inventointi) aineistojen perusteella (kuva 1). Etenkin laadultaan hyvien taimikoiden määrä on laskenut viimeisten vuosien aikana. Varttuneissa taimikoissa voidaan havaita selkeä muutos laadun heikentymisessä (kuva 1).



Kuva 1. Pienten ja varttuneiden taimikoiden laatu kolmen viimeisimmän valtakunnan metsien inventoinnin mukaan. (Metsätieteen aikakauskirja 4/2010, Korhonen ym. 2010 sekä elektronisena <http://www.metla.fi/aikakauskirja/full/ff10/ff104425.pdf>)

Syyt taimikoiden laadun heikentymiseen eivät pelkästään johdu hoitamattomuudesta, mutta sen osuus on kuitenkin merkittävä, kuten samaisessa Korhosen ym. (2010) tutkimuksessa käy ilmi (kuva 2).



Kuva 2. Taimikoiden laadun alennuksen syyt uudistamismenetelmin (Metsätieteen aikakauskirja 4/2010, Korhonen ym. 2010 <http://www.metla.fi/aikakauskirja/full/ff10/ff104425.pdf>)

Riukuuntumisen seurauksena puunkorjuunkustannukset nousevat, sillä kuitupuuksi kelpaavaa puuta saadaan vähemmän ensimmäisiltä harvennuksilta (kuva 3). Hoitamattomassa ja riukuuntuneessa metsässä myös luonnonpoistuman määrä kasvaa, koska kasvutilaa ja valoa ei riitä kaikille rungoille (Hyvän metsänhoidon suositukset, Tapio 2006). Sen sijaan oksien määrä vähenee, mikä parantaa rungon laatua (Kärkkäinen M, 2003). Riukuuntunut metsä voidaan kuitenkin hoitaa suorittamalla energiapuuharvennus. Energiapuuharvennuksessa myös pienemmät rungot kelpaavat talouskäyttöön, minkä vuoksi harvennus on mahdollista suorittaa pienemmillä kustannuksilla. Harvennuksella on myös mahdollista tehdä integroidusti eli harvennuksessa otetaan talteen sekä aines- että energiapuuta. Metsätalouden kannalta on kuitenkin taloudellisempaa, että taimikonhoito tehtäisiin ajoissa, jolloin turvattaisiin mahdollisimman suuri tukki- ja kuitupuun (ainespuun) määrä. Vaihtoehtoisesti on myös mahdollista viivästyttää ensiharvennusta, jolloin ensiharvennukselta saadaan suurempi puumäärä talteen. Useissa tutkimuksissa tämä vaihtoehto on myös taloudellisesti kannattavaa koron ollessa pieni, mutta myös tällöin integroitu korjuu toisi lisäarvoa hoitotyölle. (mm. Metsähallituksen metsätalouden julkaisuja 53, 2004)

		Alnespuukertymä, m ³ /ha Roundwood removal (m ³ ob/ha)								
		30-55	40-65	50-75	60-85	73-95	85-105	95-115	108-125	120-135
1	N	20	30	40	50	60	70	80	90	100
Rungon koko Stem size dm ³		Kustannussäästö korjuukustannuksissa, €/m³ Savings in harvesting costs (€/m³ob)								
40	40	1,4	1,0	0,7	0,6					
50	50	1,4	1,0	0,8	0,6	0,5				
60	60	1,4	1,0	0,8	0,6	0,5	0,5	0,4		
70	70	1,4	1,0	0,8	0,7	0,6	0,5	0,4	0,4	
80	80	1,4	1,0	0,8	0,7	0,6	0,5	0,4	0,4	0,3
90	90	1,5	1,1	0,8	0,7	0,6	0,5	0,4	0,4	0,4
100	100	1,5	1,1	0,8	0,7	0,6	0,5	0,4	0,4	0,4
110	110	1,5	1,1	0,9	0,7	0,6	0,5	0,5	0,4	0,4
120	120	1,5	1,1	0,9	0,7	0,6	0,5	0,5	0,4	0,4
130	130	1,5	1,1	0,9	0,7	0,6	0,5	0,5	0,4	0,4
140	140	1,5	1,1	0,9	0,7	0,6	0,5	0,5	0,4	0,4

Korjattavan puuston rungon koko kasvoi 25 % Stem size of the trees to be harvested increased by 25%										
		Alnespuukertymä, m ³ /ha Roundwood removal (m ³ ob/ha)								
		38-69	50-81	63-94	75-106	91-119	106-131	119-144	134-156	150-169
2	N	20	30	40	50	60	70	80	90	100
Rungon koko Stem size dm ³		Kustannussäästö korjuukustannuksissa, €/m³ Savings in harvesting costs (€/m³ob)								
50	40	6,0	5,4	5,1	4,8					
65	50	5,3	4,7	4,4	4,1	4,0				
75	60	4,6	4,1	3,8	3,6	3,5	3,3	3,2		
88	70	4,3	3,8	3,5	3,3	3,2	3,0	3,0	2,9	
100	80	3,9	3,4	3,2	3,0	2,9	2,7	2,7	2,6	2,5
113	90	3,7	3,3	3,0	2,8	2,7	2,6	2,5	2,4	2,4
125	100	3,5	3,1	2,8	2,6	2,5	2,4	2,3	2,2	2,2
138	110	3,4	2,9	2,7	2,5	2,4	2,3	2,2	2,1	2,1
150	120	3,2	2,8	2,5	2,4	2,2	2,1	2,1	2,0	1,9
163	130	3,1	2,7	2,5	2,3	2,2	2,1	2,0	1,9	1,9
175	140	3,0	2,6	2,4	2,2	2,1	2,0	1,9	1,8	1,8

Kuva 3. Korjattavan ensiharvennuspuun koon vaikutus korjuukustannuksen säästöihin (Metsätehon katsaus nro 22, 2006 sekä elektronisena http://www.metsateho.fi/files/metsateho/Katsaus/Katsaus_022.pdf)

Tällä hetkellä metsänhoitotarpeen määrittäminen tehdään maastotarkistusten avulla. Maastotarkistamiset vievät suunnittelijoilta aikaa, jota voitaisiin kohdentaa muihin tehtäviin, jos osa maastotarkistuksista voitaisiin tulevaisuudessa vähentää. UPM Kymmene Oyj:llä jokaisesta metsätalouksuviosta löytyy tietoa uudistamismenetelmästä, uudistamisen ajankohdasta sekä kuvion kasvupaikan tiedoista. Lisäksi yhtiöllä on kerättyä omista metsistä lasertietokanta, minkä avulla voitaisiin kehittää metsänhoidon suunnittelua ja etenkin metsänhoitotoimenpiteiden ajoituksen toteuttamista. Laserkeilausperusteisella inventoinnilla saadaan tarkka inventointitieto 3D -muodossa, mikä tekee päätöksenteon helpommaksi. Lisäksi metsänhoidollisesti

merkityksellisten simulointikasvatusten tarkkuus on parempi tulevaisuuden päätöksille, kun inventointitieto on parempaa ja ajankohtaisempaa. Energiapuunkorjuussa laserkeilausta voitaisiin hyödyntää kohteiden löytämisessä ja leimikon rajojen piirtämisessä. Mikäli laserkeilausperusteisella inventoinnilla voitaisiin määrittää toimenpiteen tarve tai ajankohta, olisi se erittäin kustannustehokas vaihtoehto inventointeihin. Suvanto ym. (2005) tutkimuksen mukaan puustotunnukset voidaan ennustaa laserkeilauksella riittävällä tarkkuudella. Tutkimuksessa mallit tuottivat laadinta-aineistossaan puuston keskiläpimitan, keskipituuden, runkoluvun, pohjapinta-alan ja tilavuuden osalta seuraavat absoluuttiset ja suhteelliset keskivirheet (RMSE): 1,9 cm (9,5 %), 1,9 m (5,3 %), 274 kpl/ha (18,1 %), 2,0 m²/ha (8,3 %), ja 19,9 m³/ha (9,8 %). Myös Juntunen (2006) tutki laserkeilauksen käytettävyyttä, mutta hänen tutkimuksessaan keskityttiin puustotiedon laadun vaikutukseen metsänkäsittelyn optimoinnin tuloksiin. Tutkimus vertaili UPM Metsän kuviotietojen ja laserkeilauspohjaisen inventoinnin eroja. Tutkimuksen mukaan laserperusteinen inventointi on tarkkuuden osalta sopiva metsänkäsittelytoimenpiteiden laatimiseen.

Närhi (2008) tutki omassa gradussaan kuusen taimikoiden inventointi- ja taimikonhoidon kiireellisyyden määrittämistä laserkeilauksen ja metsäsuunnitelmatietojen avulla. Tutkimuksen mukaan laserkeilaus on soveltuva menetelmä taimikonhoidon kiireellisyyden arviointiin. Tutkimuksessa kiireellisten, seuraavan 5 vuoden hoitokohteiden ja ”Ei hoitotarvetta vaativien” -hoitokohteiden oikeinluokittumisprosentti oli 71,8 %. Taimikon perkaustarpeen määrittämistä on tutkittu myös numeerisen ilmakuvan avulla Tuomolan ym. (2006) tutkimuksessa. Kyseisessä tutkimuksessa kasvatettavien havupuiden puustotunnukset saatiin arvioitua 63 - 70 % tarkkuudella, mutta kilpailevien lehtipuiden pituus ja tiheysmallit ainoastaan 29 - 34 % selitysasteella. Tutkimus toteaa, että numeerista ilmakuva ei voi yksin käyttää perkaustarpeen määrittämiseen, mutta yhdessä muiden inventointimenetelmien kanssa se on käyttökelpoinen.

Näiden tutkimusten pohjalta päätin tutkia mitä mahdollisuuksia laserkeilausperusteinen inventointi voisi tuoda metsänhoitotoimenpiteiden määrittämiseksi. Rajasin työni keskittyen hoitamattomiin ensiharvennusmetsiköihin ja sitä nuorempiin metsiköihin lukuun ottamatta varhaisperkauksia, joissa puuston keskipituus on vähemmän kuin 2 metriä. Työni tarkoituksena

on tukia, onko mahdollista löytää hoitamattomat taimikot sekä energiapuukorjuuseen kelpaavat kohteet käyttäen laserkeilausperusteista inventointia.

1.2 Teoreettinen viitekehys

1.2.1 Taimikko ja taimikonhoito

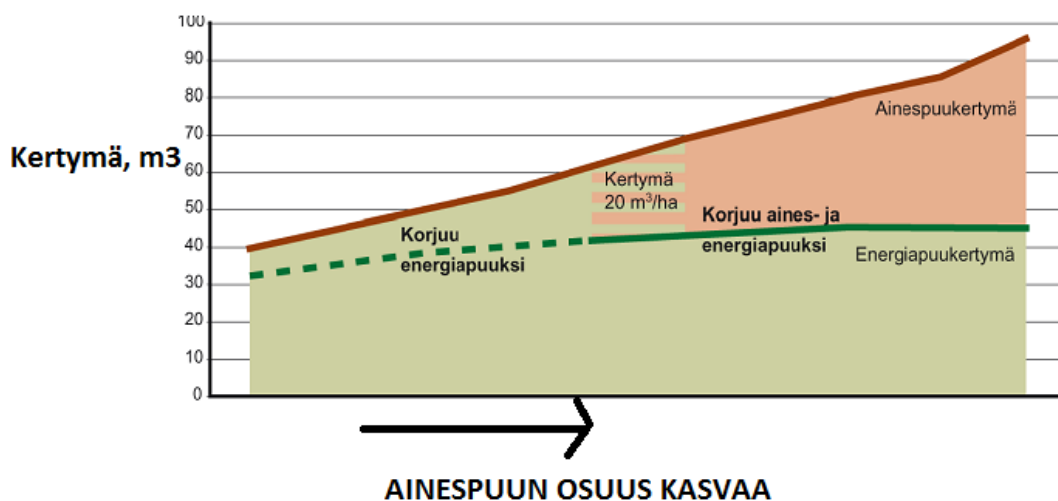
Työssä taimikoksi ovat määritelty kaikki alle 8 metriä valtapituudeltaan olevat metsiköt. Metsiköt, joiden keskipituus oli alle 2 metriä, on jätetty teknisistä syistä tarkastelun ulkopuolelle, sillä laserkeilausperusteisella inventoinnilla metsiköistä, joiden keskipituus oli alle 2 metriä, ei vielä työni alkamisen aikana saatu riittävän tarkkaa inventointitietoa. Rinnankorkeusläpimitan mukaista jaottelua taimikoiden ja ensiharvennusten suhteen ei ole työssä otettu huomioon. Taimikonhoidon ajoituksessa on käytetty hyvän metsänhoidon suosituksia (Tapion julkaisuja 2006) sekä UPM Kymmene Oyj:n omia toimintaohjeita (ei saatavissa vapaasti). Taimikonhoidon tarve riippuu työssäni runkoluvusta alla olevan kaavion mukaan (kuva 4). Kaaviossa on myös esiteltyä energiapuuharvennusten luokittelu. Työssä en keskity taimikonhoidon oikeanlaiseen ajoitukseen, sillä UPM Metsä hoitaa ajoituksen pituuden mukaan. Työn yksinkertaistamisen vuoksi luokittelussa ei ole erikseen luokiteltu energiapuukorjuun ja taimikonhoidon eri menetelmiä. Esimerkiksi varhaisperkaus ja muut taimikonhoidon muodot on merkitty yhtenä luokkana ja energiapuukorjuukohteet yhtenä luokkana.



Kuva 4. Kohteiden luokittelukaavio pro gradu -työssäni

1.2.2 Energiapuuharvennuskohde

Kohteiden jaottelun lähtökohtana päätin käyttää Metsätehon korjuun määrätymisen ohjetta (http://www.metsateho.fi/files/metsateho/Opas/Korjuun_suunnittelu_ ja_toteutus_ver02.pdf). Kertymää on oltava riittävästi, jotta energiapuuharvennus on järkevää suorittaa. Kertymän kasvaessa on järkevää toteuttaa integroitu aines- ja energiapuukorjuu. Oheisen ohjeen määrätymisen voi nähdä kuvasta 5.



Kuva 5. Energiapuukorjuun määrätyminen Metsätehon ohjeiden mukaan.

Työssäni oli myös tarkoitus tarkastella ennakkoraivauksen tarvetta, joten kyseistä ohjetta en voinut suoraan käyttää. Korjuukohteessa on myös huomioitava metsikön kasvupaikka sekä ympäristökysymykset. Taulukossa 2 on käytynä läpi soveltuvuuteen vaikuttavat tekijät. Työssäni maastoinventoinnin aikana en törmännyt kohteisiin, jotka eivät soveltuisi energiapuukorjuuseen, sillä soveltumattomat kohteet oli helppo rajata pois kuviotietojen avulla. Lisäksi on mainittava, että laserkeilausperusteisella inventoinnilla on vaikea päästä kiinni osaan kyseisistä tunnuksista kuten turpeen paksuuteen tai ravinne-epätasapainosta tai -puutoksesta kärsiviin kohteisiin. UPM-Kymmene Oyj:llä on kuitenkin kattavat tiedot kuvioista ja ennalta tehdyistä toimenpiteistä, joten työssäni keskityin lähinnä kohteen valitsemiseen hoitotarpeen ja kustannustehokkuuden perusteella. Tutkin myös, onko mahdollista käyttää peruskuviotunnuksia apuna luokittelun suorittamiseksi. Peruskuviotunnuksia, jotka valitsin, olivat maalaji (turve vai kivennäismaa), pääpuulaji ja kasvupaikkaluokka.

Taulukko 2. Pienpuun korjuun ympäristöohje (UPM Kymmene Oyj:n Nuorenmetsän kunnostuksen toimintaohje, ei julkisesti saatavilla).

Kohdevalinta	Soveltuvuus
Kuivahkot ja sitä rehevämmät kankaat sekä vastaavat turvemaat - nuoret ylitiheät metsät - ainespuuksi kelpaamaton verhopuusto kuusentaimikoista - yhdistetyt energia – ainespuun kasvatusmetsät	Kyllä
Karut kasvupaikat, mikäli rangat karsitaan	Kyllä
Paksuturpeiset turvemaat, kun kohde terveyslannoitetaan	Kyllä
Hoitotarpeessa olevat ojitettujen turvemaiden nuoret metsät	Kyllä
Ohutkuntaiset kuivahkot kankaat	Ei
Hoidetut kuusivaltaiset (yli 75 %) kohteet	Ei
Arvokkaat luonto- ja kulttuurikohteet	Ei
Ravinne-epätasapainosta tai -puutoksesta kärsivät kuviot	Ei
Runsaasti järeeää runkolahopuuta sisältävät kuvion osat	Ei

Metsätehon ohjeen lisäksi UPM Kymmene Oyj ohjeisti tutkimuksen alussa, että energiapuuharvennuskohteeksi ovat määritelty yli 10 metriä keskipituudeltaan olevat metsiköt, joiden kantolämpimitaltaan yli neljä senttimetrinen runkojen määrä on yli 3500 kappaletta hehtaarilla. Lisäksi energiapuuharvennuskohteeksi ovat määritelty pituudeltaan 7-10 metriset metsiköt, joissa runkoluku on yli 3500, sillä näiden kohteiden voidaan arvioida olevan energiapuuharvennuskohteita 3-5 vuoden kuluttua. Kuitenkin korjuukustannukset ovat vaikuttavin tekijä korjuuajankohtaan ja korjuun toteuttamiseen. Tämän takia työssäni energiapuukorjuukohteet on luokiteltu kertymän mukaan. Mikäli yllämainitut ehdot täyttyvät, sekä kertymän ollessa yli 30 m³/ha, kyseessä on energiapuuharvennuskohteeksi. Lisäksi UPM Kymmene Oyj toivoi, että myös keskimääräinen korjattavan rungon koko olisi riittävän iso energiapuukohteilla, joten kohteet, joissa kertymä on suuri, mutta korjattavan rungon keskikoko on pieni, luokiteltaisiin ennakkoraivauskohteeksi, mikä on taimikonhoidon ja energiapuuharvennuskohteen rajamuoto. Ennakkoraivauksessa on tarkoituksena poistaa pienet kantolämpimitaltaan noin 2 cm rungot, joista ei ehdi kehittyä seuraavaan harvennukseen.

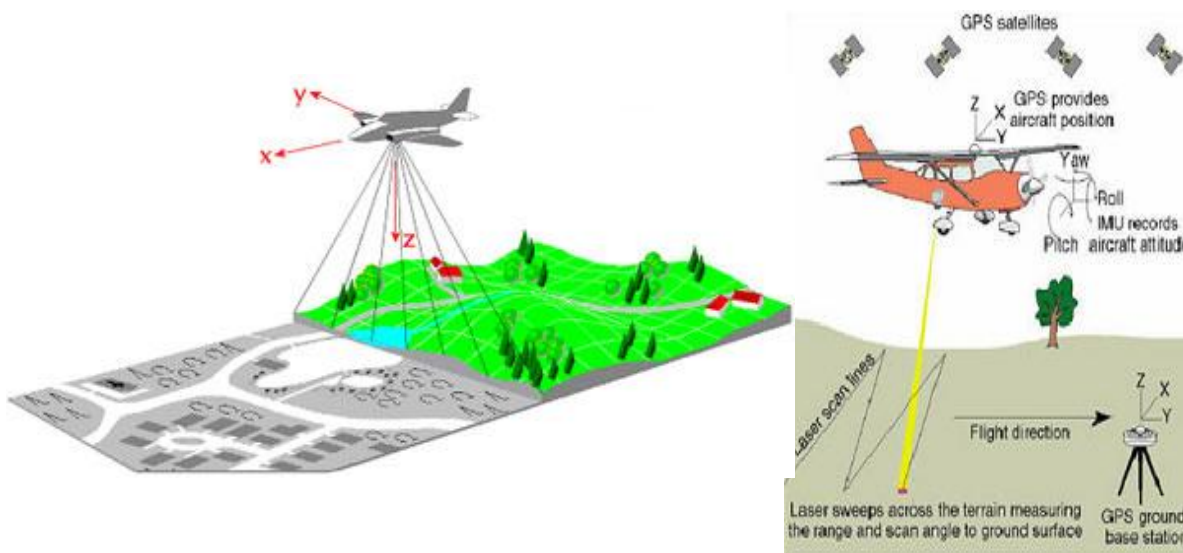
kunnollisia energiapuita. Näiden kriteerien mukaan tein maastossa subjektiivisen luokittelun kohteille.

Objektiivisessa luokittelussa läpimittaa ei ole otettu huomioon, vaan kohteet on jaoteltu poistumien mukaan sekä valtapituuden mukaan. Valtapituuden täytyy olla suurempi kuin 8 metriä, jotta kohde on nuorenmetsänkunnostuskohde. Poistuman tulee olla kuutiomäärältään yli 30 m^3 , mutta mikäli tämä ehto ei täyty poistumaltaan runkoluvun on oltava vähintään 3000 runkoa/hehtaari. Jälkimmäisessä tapauksessa kyseessä on ennakkoraivaus (kuva 4).

Pituuden ja järeyden kasvaessa on ehdotuksena integroitu energiapuuharvennus tai normaali ensiharvennus. Työn ulkopuolelle rajataan siis normaalit ensiharvennusleimikot, jotka eivät ole riukumetsiä ja joissa tiheys on alhainen sekä tietenkin varttuneet nuoret ja vanhat kasvatusmetsät. Varttuneita kasvatusmetsiä ei ole aineistossa ollenkaan, mutta kohteita, jotka vaativat normaalin ensiharvennuksen on mittauksissa ja analyysissä mukana.

1.2.3 Laserkeilaus

Tunnetuin laserkeilausperusteinen inventointimuoto on ALS (Airborne Laser Scanning). ALS:n avulla saadaan 3D -pisteparvi, joka kuvaa maastonpintaa ja sen päällä olevaa kasvillisuutta ja josta fyysiset etäisyydet voidaan laskea suoraan. Laserkeilaimen tuottama 3D -ominaisuus tarjoaa metsäinventointiin useita eri mahdollisuuksia. Jokainen laserkeilauksen avulla tuotettu piste sisältää x-, y- ja z -arvon, minkä avulla piste voidaan sijoittaa tarkasti kartalle. Luonnossa z -arvot kuvaavat pystysuuntaisia ominaisuuksia, kuten maaston korkeutta tai metsänarvioinnissa metsän korkeutta. Verrattaessa laserkeilausta ilmakuviin, laserkeilauksella on myös mahdollista havaita visuaalisesti vaikeasti havaittavia kohteita metsästä, kuten lisävaltapuut ja aliskasvoskerros (Packalen ja Maltamo 2007.). Etenkin tämä ominaisuus on tärkeä työni kannalta, sillä energiapuuukohteissa ja hoitamattomissa taimikoissa kyseisten runkojen määrä on suuri.



Kuva 6. Lentoalusperusteisen laserkeilauksen periaate. Keilaimen leveydeltä saadaan tarkat x, y ja z-tiedot maastosta 3D -pisteparvena. Lentokone on yhteydessä satelliitteihin ja lentoreitti tallentuu tarkasti IMU -järjestelmän avulla, jolloin keilaamalla saadut pisteet voidaan sijoittaa tarkasti kartalle. (kuva [lähteestä http://www.geoinformatics.com](http://www.geoinformatics.com) ja http://www.aeromaps.com/images/LiDAR_5.jpg)

Laserkeilausperusteinen inventointi lentoaluksen avulla käyttää LiDAR -tekniikkaa (Light Detection and Ranging), joka perustuu valon nopeuden tuntemiseen ja mittaamiseen. Lentokoneessa oleva laserkeilain lähettää laserpulssin (yleensä infrapuna-alueella), joka heijastuu kohteesta takaisin ilmaisimelle, jolloin voidaan määrittää kohteen ja laserin välinen etäisyys pulssin kulkuajan perusteella. Kun lasertykin asento ja paikka tunnetaan tarkasti, mitattu etäisyys lasertykin ja kohteen (kuten alla oleva metsikkö) välillä voidaan muuttaa sijainniksi 3D -koordinaatistossa. Laserin asento ja sijainti määritetään tavallisesti inertiajärjestelmän ja GPS-mittauksen (Global Positioning System, maailmanlaajuinen satelliittiverkosto paikantamiseen) avulla. Inertiajärjestelmä mittaa joko pelkkää asentoa, tai asentoa ja paikkaa inertia-antureita käyttäen. Laserkeilaintekniikan GPS-mittauksessa yksi GPS-vastaanotin on samassa lentävässä alustassa kuin laserkeilain ja maassa on referenssiasema tutkittavan alueen lähietäisyydessä, esimerkiksi 30 km säteellä. (Hyyppä J. elektroninen lähde)

Aikaisemmin laserkeilauksen tuottaman pisteparven tulkinnessa oli ongelmana analysoida laserkaikujen ja todellisen puuston yhteys eli mistä kaiku todellisuudessa syntyi: latvasta, maasta

vai siltä väliltä. Algoritmit perustuivat tilastomatemattisiin oletuksiin. Esimerkiksi sivuiltaan 15 m neliön sisältä etsittiin korkeimman ja matalimman laserpulssin heijastuskorkeudet (Næsset, 1997) ja erotus oletettiin puuston pituudeksi tai pulssimäärää verrattiin todennäköiseen puustotiheyteen ja valittiin todennäköisyyttä vastaavat suurimmat korkeudet. (Hyypä J. elektroninen lähde)

LiDARin käyttöä metsäinventoinnissa on käytetty jo 1988 Nelsonin tutkiessa sen tuomia mahdollisuuksia metsikkötunnusten tuottamiseen. Næssetin (1997) tutkimuksessa käytössä oli jo parempi teknologia ja tarkkuus myös sitä myöten parempi, mikä teki laserkeilauksesta erittäin tunnetun apuvälineen ja tutkimisen kohteen. Laserkeilausperusteista inventointia voidaan tehdä myös satelliitti- (Drake 2004) tai maastoalustaperusteisesti (Lowell ym. 2003), mutta työssäni keskityin pelkästään lentoalusperusteisen laserkeilauksen käyttämiseen metsäinventoinnissa ja -suunnittelussa.

Laserkeilausperusteisen inventoinnin tarkkuudesta on tehty useita tutkimuksia (Magnussen & Boudewyn 1998; Lim ym. 2003; Næsset 2004) sekä sen kustannusten laskemisesta (Eid ym. 2004). On siis oletettavaa, että laserkeilauksen käyttäminen metsien inventoinnissa tulee lisääntymään. Packalénin (2006) tutkimuksessa myös eri puulajien tilavuuksista saatiin luotettavat tulokset männyn, kuusen ja lehtipuiden välillä. Yksinpuintulkinta vaatii yli viiden pulssin tiheyttä neliometriä kohden (Hyypä & Inkinen 1999 sekä Solberg ym. 2006), mutta koska kyseisen aineiston hinta on vielä kallis, ei työni kannalta ollut järkevää tutkia yksinpuintulkinnan mahdollisuuksia hoitokohteiden löytämisessä. Laserkeilausperusteisella inventoinnilla voidaan tuottaa metsikkötunnuksia solutasolle (Grid) (Næsset 2004), mikrokuviotasolle (Packalen 2006) sekä suoraan koko metsikkökuviolle (Suvanto 2005). Harvempipulssisella aineistolla inventoinnin tarkkuus laskee (Næsset ja Okland 2002). Brandtberg ym. (2003) totesivat tutkimuksessaan, että lehtipuut voidaan mitata tarkasti, vaikka ne ovat lehdettömiä (syksyllä ja keväällä). Työni kannalta tärkeää on myös mainita Maltamon ym. (2005) tutkimus, joka osoitti, että myös aliskasvokset voidaan havaita laserkeilausperusteisella inventoinnilla eli laserpulssit läpäisevät myös latvuserroksen, kun tarkastellaan heijastuneiden kaikujen korkeusjakaamaa. Tutkimus kuitenkin osoitti, että tulosten tarkkuus riippui valtapuiden latvuserroksen tiheydestä. Mehtätalo (2006) tutki myös pienten puiden havaitsemista

laserkeilausaineiston avulla ja onnistui luomaan matemaattisen kaavan pienten puiden tunnistamiseksi. Kaiken kaikkiaan voidaan todeta, että laserkeilausta voidaan käyttää monipuolisesti metsäinventoinnissa ja suunnittelun työkaluna.

Metsäsovelluksissa lentoalus normaalisti lentää 200–2000 metrin korkeudessa keilattaessa pisteparvea. Keilauskulma vaihtelee 7–15 asteen välillä ja pulssin tiheys aina harvapulssisesta 0,1–2 pulssia per neliometri tiheäpulsseen 2–10 pulssia per neliometri.

Laserkeilauksen käytettävyyttä lisää sen avulla saatava maastopintamalli (Digital Terrain Model, DTM). Lisäksi saadaan kasvillisuuden korkeusmalli tai latvuston korkeusmalli (Canopy Height Model, CHM), poistamalla maanpintaan osuneet pisteet sekä alle kahden metrin korkeudessa olevat maaperä- ja pensasosumat pisteparvesta. Maanpinnan tasomallia ja pisteitä, jotka ovat alle kahden metrin korkeudessa, voidaan myös käyttää erilaisissa tutkimustarpeissa, mutta työssäni en katsonut sen antavan lisäarvoa, joten jätin kyseiset pisteet tarkastelun ulkopuolelle. Laserkeilauksen käyttämisessä metsäinventointiin voidaan käyttää kahta lähestymistapaa: yksinpuintulkintaa tai kasvillisuuden laserpisteiden korkeusjakaamaa. Yksinpuintulkinta soveltuu ainoastaan tiheäpisteiselle laserkeilausaineistolle, joten työni perustuu saadun korkeusjakauman käyttämiseen.

1.2.4 Lasertunnukset

Latvuston korkeusjakauman käyttöönottoaminen vaatii, että orthometriset laserkeilauspisteet muunnetaan maanpinnan yläpuolisiksi pisteiksi käyttämällä maanpinnantason mallia hyväksi. Tämän jälkeen voidaan muodostaa ensimmäisen ja viimeisen kaiun laserpisteiden korkeusjakauman prosenttipisteet, joiden avulla pyritään kuvaamaan mitattavan alueen puuston rakennetta ja kokoa. Työssäni käytössä oli 5, 10, 20,.. 90, 95 ja 100 (h_5, \dots, h_{100}) korkeusjakauman prosenttipisteet sekä vastaavat tiheysarvot (p_{05}, \dots, p_{100}). Esimerkiksi arvo h_{20} tarkoittaa korkeusarvoa, jossa 20 prosenttia kaikista laserosumakorkeuksista kasvillisuuteen on kerääntynyt. Arvo p_{20} on taas suhdeluku nollan ja ykkösen välillä, joka osoittaa suhteen laserosumista, jotka ovat kerääntyneet korkeudessa 20 %. Näiden parametrien lisäksi käytössäni on ensimmäisen kaiun ja viimeisen kaiun kasvillisuusosuus (f_{veg} ja l_{veg}), joka laskettiin jakamalla kaikkien yli korkeusrajoitteen yläpuoliselle korkeudelle osuneiden laserpulssien

lukumäärä koko koealalle osuneiden laserpulssien kokonaismäärällä (Næsset 2004). Kasvillisuusosuudella pyritään kuvaamaan metsikön suhteellista tiheyttä: mitä suurempi kasvillisuusosuus on, sitä tiheämpi metsikkö on.

Näitä lasertunnuksia on käytetty muun muassa regressio- ja ei-parametrisissa malleissa, kun on haluttu ennustaa puuston keskipituutta, pohjapinta-alaa, läpimittaa ja tilavuutta (Næsset 1997, Næsset ja Okland 2002, Næsset 2002 ja Maltamo ym. 2006). Packalén & Maltamo (2007) käyttivät ei-parametrista k-lähimmän naapurin menetelmää kyseisten tunnusten ennustamisessa ja pääsivät tuloksiin, jotka olivat samalla tarkkuudella kuin nykyisellä kuviokohtaisella maastoinventoinnilla Suomessa. Oman työni menetelmistä kerrotaan kappaleessa 3.

1.2.5 Mikrokuvio

Mikrokuvio on kooltaan erittäin pieni kuvio, joka suurimmillaan voi muistuttaa pientä metsätalouskuviota. Mikrokuviosta käytetään myös nimitystä puustokuva, jota käytän synonyyminä mikrokuvion kanssa tässä työssä. Yksi metsätalouskuvio voi sisältää useita mikrokuvioita. Mikrokuvioille on ominaista pienen koon lisäksi puuston homogeenisuus eli samankaltaisuus (Hyvönen ym. 2005). Mikrokuvioiden käyttöä puoltaa se, että metsätalouskuvioden sisäinen vaihtelu on suurta, ja joskus jopa pääpuulaji on eri kuvion eri osissa, mikä hankaloittaa suunnittelussa tarkkaa päätöksentekoa. Tosin mikrokuvio ei ole vielä operatiivisessa käytössä, mutta UPM Kymmene Oyj on tehnyt tutkimuksia sen käytöstä myös operatiiviseen käyttöön. Normaalisti mikrokuvioita käytetään vain inventointitarkoituksessa. Tässä työssä käytin normaalien metsäkuvioiden sijasta mikrokuvioita, jolloin oli mahdollista saada mahdollisimman pieni sisäinen vaihtelu kuvion sisällä, mutta suuret vaihtelut eri kuvioiden välillä. Mikrokuvioiden mittaaminen ja tarkastaminen oli myös nopeampaa kuin jos olisin käyttänyt metsätalouskuvioita.

1.3 Tutkimuksen tavoitteet

Tutkimuksen tavoitteena oli luoda laserkeilausaineistoon perustuva menettely puustokuvion toimenpidetarpeen määrittämiseksi. Toimenpiteet oli tässä työssä rajattu

taimikonhoitoon ja nuoren metsän energiapuuhakkuuseen. Tutkimuksen tarkoituksena oli tutkia, mitkä lasketut lasertunnukset kuvaavat hyvin eri kohteita ja miten niistä voisi muodostaa mallin, jonka avulla voitaisiin löytää kuviot, jotka vaativat hoitotoimenpiteitä.

Toimenpidetarpeen määrittelyssä pyrittiin pienentämään toimenpidetarpeeltaan epävarmojen ja maastotarkistusta vaativien kohteiden määrää mahdollisimman pieneksi, kuitenkin vähentämättä varmojen kohteiden (toimenpidetarve/ei toimenpidetarvetta) oikeellisuutta. Varmojen kohteiden oikeellisuuden tavoite oli yli 90 %, jotta ne voitaisiin jättää maastotarkistuksen ulkopuolelle myöhemmin UPM Metsän sovelluksissa.

Tutkimuksen tavoitteena oli kehittää toimenpidetarpeen määrittämisen malli suoraan laseraineiston pisteparvesta sekä käyttämällä tunnettuja kuvion perustietoja. Ennusteen oikeellisuutta testattiin perinteisiin puustotunnuksiin perustuvaa luokittelumallia vasten sekä myös maastossa suoritettuun subjektiiviseen arvioon hoitotarpeesta. Luokittelumallissa käytettävät puustotunnukset on saatu keräämällä maastoaineisto kesän 2009 aikana 102 mikrokuviolta.

Tutkimuksen tuloksena saadaan tietoa kahden eri lähestymistavan (luokittelu ennustettujen puustotunnusten kautta ja suora mallinnus) luotettavuudesta toimenpidetarpeen määrittämisessä, taustamateriaalia menetelmävalintaa varten ja mahdolliset kehitystarpeet, mitä laserkeilausperusteiseen inventointiin tarvitaan.

Tutkimuksen tavoitteena oli myös löytää hyvin selittäviä tunnuksia laseraineistosta, joiden perusteella voitaisiin löytää energiapuuharvennusta tai taimikonhoitoa vaativat kohteet. Näitä tunnuksia käyttäen sekä olemassa olevaa perustietoa mikrokuvioista käyttäen laaditaan lisäksi malli, jonka avulla mikrokuviot luokitellaan toimenpidetarpeen mukaan: toimenpidettä vaativiin (nuorenmetsänkunnostus ja taimikonhoito) ja ei toimenpidettä vaativiin.

Oletuksenani oli, että tiheänä kasvaneessa metsässä suurin osa laserimpulsseista heijastuu takaisin jo latvuskerroksesta ja maahan osuneita impulsseja on ainoastaan vähän. Ajoitukseen taas pääsisi kiinni pituuden avulla, koska UPM käyttää valtapituutta hoitotarpeen päätöksenteossa.

Mikäli hoitotarve täyttyy, mutta valtapituutta ei ole tarpeeksi, kohde on toteutettavissa muutaman vuoden kuluttua. Laserperusteisella inventoinnilla löydetyt nuoren metsän kunnostuskohteet voidaan puolestaan erottaa toisistaan myös valtapituuden ja läpimitan avulla. Suuriläpimittaiset kohteet menevät integroituna korjauksena, koska oletuksena on, että kohteelta saadaan myös sellupuuta. Mikäli läpimitta ja pituus ovat pieniä, kyseessä on joukkokäsittelykohde tai vastaavasti ennakkoraivaus.

2. Aineisto

Aineisto kerättiin kesäkuun ja heinäkuun aikana 2009. Aineistoa kerättiin Pohjois- Savon alueella: Rautavaaran, Sonkajärven, Varpaisjärven, Nilsiän, Kuopion, Suonenjoen ja Karttulan kunnissa. Mitattavat alueet sijaitsivat kaikki UPM Kymmene Oyj:n omistamilla metsäpalstoilla. Aineiston keruussa avusti ensimmäiset kolme viikkoa yliopiston harjoittelija Piritta Pyörälä, joka keräsi samalla aineistoa kandidaatin tutkielmaansa.

Ennen maastotöitä laadittiin esisuunnitelma mitattavista kohteista käyttäen MapInfo -paikkatieto-ohjelmistoa. Mitattavat kohteet haettiin käyttäen uusinta voimassa olevaa puustotulkintaa mikrokuvioille. Puustotulkinta saatiin metsien kaukokartoitukseen erikoistuneelta Blom -yhtiöltä. Kohteiden valintaan vaikuttivat runkoluku, pituus ja puulaji. Näiden suureiden perusteella mikrokuviot esiluokiteltiin selkeästi toimenpidettä vaativiin, epävarmoihin sekä ei toimenpidetarvetta. Ennen maastoa laadittiin maastolomake mittauksille sekä tulostettiin tarvittavat kartat. Ensimmäisenä maastopäivänä käytiin läpi mikrokuvioäsitettä maastossa sekä käytiin läpi mittaustekniikat.

Maastoaineiston keräämisessä mitattavat kohteet sijoitettiin suunnattua ryväotantaa soveltaen siten, että esiluokitellun mikrokuvioikartan avulla arvottiin mitattava kohde, jonka ympäriltä mitattiin myös muita mikrokuvioita yhdestä aina viiteen kappaleeseen, jolloin siirtymisiin ei tarvinnut käyttää niin paljoa aikaa. Mittaukset pyrittiin suuntaamaan tasaisesti toimenpidettä vaativien, epävarmojen sekä ei toimenpidettä vaativien kesken mittauksen alkuvaiheessa. Mittausten loppupuolella keskityttiin pelkästään toimenpidettä vaativiin sekä epävarmoihin kohteisiin, jotta näiden kahden luokan välille löytyisi selkeämpi rajapinta. Kohteita mitattiin yhteensä 102 kappaletta. Kohteiden jakauma eri hoitotoimenpiteiden mukaan voidaan nähdä taulukosta 3. Objektiiivisella tarkastelulla tarkoitetaan kohteiden luokittelua mitattujen puustotunnusten avulla. Maastotarkasteluperusteinen luokittelu perustuu subjektiiiviseen arvioon hoitotoimenpiteen tarpeellisuudesta. Työssäni objektiiivinen tarkastelu on tärkeämmässä asemassa ja maastotarkastelua käytettiin ainostaan aputyökaluna tulosten lopputarkastelussa. Kahden luokan tapauksessa kohteet on jaettu hoitotarvetta vaativiin ja ei hoitotarvetta vaativiin. Kolmen luokan tapauksessa kohteet on puolestaan jaettu nuoren metsän kunnostuskohteiksi,

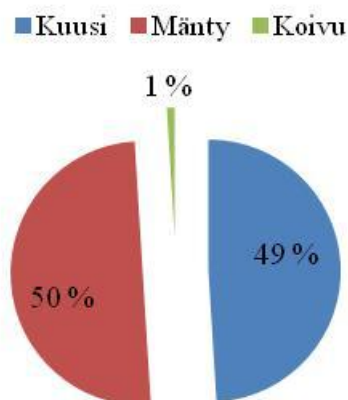
taimikonhoitokohteiksi ja ei hoitotarvetta -kohteiksi. Neljän luokan tapauksessa jaottelu on sama kuin kolmen, mutta nuoren metsän kunnostuskohteet on jaettu erikseen energiapuuharvennuskohteeksi ja ennakkoraivauskohteeksi.

Taulukko 3. Mitattavien kohteiden määrä maastotarkastelun ja objektiivisen tarkastelun mukaan.

LUOKITTELU, SUBJEKTIIVINEN JA OBJEKTIIVINEN					
	2 lk-obj	3 lk-obj	4 lk-obj	2 lk -subj	3 lk -subj
Hoitotarve	77	77	77	37	37
Nuoremetsänkunnostus		34	34	13	
- Energiapuuharvennus			13		
- Ennakkoraivaus			21		
Taimikonhoito		43	43	24	
Ei hoitotarvetta	25	25	25	65	65
YHTEENSÄ	102	102	102	102	102

Maastotyöt pyrittiin kohdentamaan mahdollisimman monipuolisesti eri kasvupaikan, pääpuulajin ja maalajin kohteisiin, jotta tulokset olisivat luotettavat myös isommalle aineistolle. Kohteiden jakaumat kyseisten tunnusten mukaan voidaan nähdä kuvista 4, 5 ja 6. Pääpuulajin osalta keskityin tutkimaan lähinnä havupuukohteita, sillä UPM Kymmene Oyj:llä ei ollut lehtipuuvaltaisia hoitamattomia kohteita kuin yksi (kuva 7).

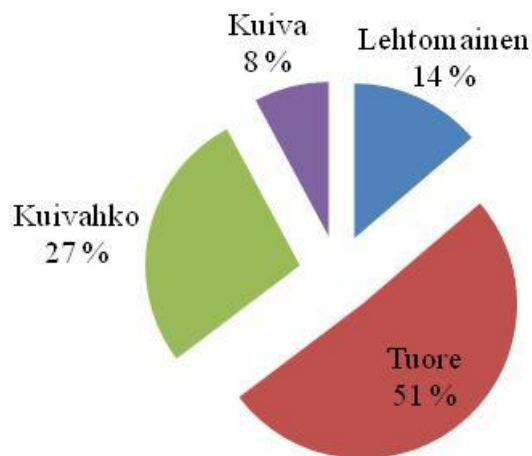
Kohteiden pääpuulaji jakauma



Kuva 7. Kohteiden jakauma pääpuulajin mukaan.

Myös kasvupaikan osalta kohteiden jakauma johtuu UPM Kymmene Oyj:n omistamien maiden kasvupaikkaluokituksesta (kuva 8). Kuivan kankaan kohteita olisin voinut löytää enemmän, mutta suurin osa hyvistä kuivan kankaan kohteista oli jo hoidettu normaali ensiharvennuksella tai energiapuuharvennuksella ennen maastokauteni aloitusta.

Kohteiden kasvupaikka jakauma, 102 kpl



Kuva 8. Kohteiden jakauma kasvupaikan mukaan

Suurin osa mitatuista kohteista oli kankaita. Turvekankaita, jotka olisivat kärsineet ojituksen puuttumisesta, oli vaikea löytää yhtiön metsistä. Hoitamattomia turvekankaita kuitenkin löytyi 8 % mitatuista kohteista.

Yhdeltä mitattavalta kohteelta eli mikrokuviolta mitattiin yhdestä kuuteen koealaa suhteutettuna mikrokuvion kokoon ja maastossa tehtyyn silmämääräiseen arvioon mikrokuvion homogeenisyydestä. Koealat olivat ympyräkoaloja, joiden säde oli 3,99 metriä. Koealalta mitattiin rungot puulajeittain kahdessa jaksossa: alle 8 metrin pituiset sekä yli 8 metrin pituiset. Runkoluvun mittauksessa tosin luokkien väli oli liukuva valtapituuden mukaan, eli valtapituuden ollessa pieni, jakson raja laski sen mukaan. Tämä helpotti muiden puustotunnusten mittaamista, sillä keskipuun valinta oli tämän jälkeen selkeämpää. Etenkin taimikoissa, joissa luontaisten ja viljeltyjen taimien pituus vaihteli usealla metrillä, tämä menettelytapa osoittautui käyttökelpoiseksi. Keskipuuna tässä työssä tarkoitetaan puujakson (pituus, puulaji) läpimitaltaan keskimääräistä puuta, jonka valinta tapahtui muutamaankin tarkistusmittaukseen perustuen.

Ympyräkoealalta valittiin jaksojen keskipuut muutaman tarkistusmittauksen avulla puulajeittain. Näistä keskipuista mitattiin pituus (dm) sekä läpimitta (cm). Lisäksi koealalta arvioitiin kasvupaikka, uudistustapa, varhaishoitotoimenpiteet sekä pääpuulaji. Näistä tunnuksista uudistustapa, varhaishoito sekä maalaji määriteltiin, mikäli ne olivat mahdollista määritellä luotettavasti. Tämän jälkeen koealalle arvioitiin toimenpidetarve sekä sen ajoitus. Nämä arviot pohjautuvat mitattuun tietoon vain osittain, joten ne ovat melko subjektiivisesti tehty.

Maastoaineiston keruussa käytin apuna mikrokuvioille suunnistaessa maastomikroa, jossa oli GPS. Lisäksi käytössäni oli Vertex -hypsometri, tallmeter, työntömitta, kivisyysrassi sekä metsurinmitta suureiden mittaamiseen ja määrittämiseen. Osittain ongelmana maastotöissä oli käytössä oleva puustotulkinta, jonka laatu ei ole vielä täysin tarkkaa. Lisäksi osa maastokohteista, jotka olin esiluokitellut puustotulkinnan avulla energiapuukohteiksi, oli jo hoidettu maastokauden alkaessa.

2.1 Aineiston analysointi

Laseraineiston analysointiin tarvittavan aineiston sain Blomilta (Blom Kartta Oy). Tässä työssä kohteet on lennetty lentokoneella. Laserkeilauksen teki norjalainen Blom Norkart Mapping AS. Käytössä oli Optechin ALTM 3100 laserkeilain. Laserkeilauksen lentokorkeus oli 1500 metriä maanpinnasta ja lentonopeus 75 m/s. Muita tietoja keilaimesta en saanut käyttööni. Blomilta saatu laseraineisto sisälsi tiedot mikrokuvion ensimmäisestä ja viimeisestä kaiusta eri korkeusosuuksilla, osumista kasvillisuuteen sekä ensimmäisen ja viimeisen kaiun korkeusosuuksien jakaumasta. Nämä termit on selitettynä aiemmin kappaleessa 1.1.3. Yhteensä sain käyttöön 32 eri lasertunnusta. Näistä lasertunnuksista tein eri muunnoksia (logaritointi, toiseen potenssiin korotus, neliöjuuri ja käänteisluku). Osa tunnuksista ei myöhemmässä vaiheessa osoittautunut käyttökelpoiseksi, joten lopullinen tunnusten määrä oli 150. Tunnusten muunnokset tein Microsoft Excelillä ja myöhemmin käytin Context Editoria apuna muuttaen aineiston tekstipohjaiseksi, jotta R-ohjelman olisi helpompaa lukea aineisto käyttöönsä.

Kohteiden subjektiivinen luokittelu tapahtui maastossa. Objektiiivinen luokittelu perustui maastossa tehtyihin mittaustuloksiin. Luokittelussa laskin jokaiselle mikrokuvioille puuston määrän jaksoittain (puu- ja taimijakso) hehtaarilla (m^3/ha). Lisäksi tein laskennat

harvennuspoistumasta (runkoluku sekä poistuman määrä m^3/ha). Tämän jälkeen luokittelin mikrokuviot kappaleiden 1.1.1. ja 1.1.2. mukaisesti.

3. Tutkimusmenetelmät

Tutkimuksessa käytin eri luokittelumenetelmiä tulosten laskemiseksi ja mallin laatimiseksi. Laseraineistosta pyrin löytämään tunnuksia, jotka soveltuisivat mallin rakentamiseen ja jotka antavat mahdollisimman luotettavan tuloksen toimenpiteestä ja sen tarpeesta.

Tulosten analysoinnissa ja mallin rakentamisessa käytin R -ohjelmaa. R -ohjelman perusominaisuudet eivät tarjonnet tutkimukseni kannalta riittävästi työkaluja mallin rakentamiseksi, joten jouduin lataamaan klaR -paketin sekä käyttämään sen ja MASS -paketin tuomia työkaluja, jotta mallin rakentaminen useista muuttujista onnistui. Lisäksi muunsin tutkija Inka Pippurin (MMM) tekemää ohjelmaa muuttujien valitsemisen helpottamiseksi. Mallin luonnissa käyttämäni R -ajot sekä ohjelma muuttujien valintaan löytyvät liitteenä työn lopusta. Luodun mallin tarkastelussa käytin myös SPSS -tilasto-ohjelmaa.

3.1 Tilastolliset luokittelumallit

Mallin laadinnassa on tärkeää, että malli ei ole ylioppinut mallinnusaineistossa. Tätä varten tein eri analyysejä selittävien muuttujien parametristimaattien merkitsevyydelle käyttäen R:n MASS ja klaR -pakettien stepclass- ja stepAIC -toimintoja. Työssäni ei ollut mahdollista käyttää testiaineistoa mallin toimivuuden tarkasteluun, joten tämä oli ainoa keino estää ylioppinut malli mallinnusaineistossa. Mallien laadinnassa käytin Leave One Out -menetelmää eli ristiinvalidoinnin muotoa muuttujia valitessani. Ristiinvalidoinnissa jaetaan aineisto S:n yhtä suureen osaan. Tämän jälkeen käytetään niistä S-1 kappaletta mallin muodostamiseen ja yksi kappale virheen estimointiin. Tämä toistetaan S kertaa siten, että kukin joukko on vuorollaan validointijoukkona. Jos S on yhtä kuin pisteiden lukumäärä aineistossa, kyseessä on Leave One Out -menetelmä, mikä siis tarkoittaa, että yhtä pistettä kerrallaan käytetään validointiin ja loppuja mallin sovitukseen. Lopullinen virhe-estimaatti saadaan laskemalla mallilla ennustettujen ja todellisten arvojen poikkeamat toisistaan. R-ohjelmassa ristiinvalidoinnin saa päälle omalla komennolla, mutta virhe-estimaattien laskentaan joutuu käyttämään omaa kaavaa. R -ohjelmassa

ei käytetä ainoastaan yhtä pistettä per kierros virheen estimointiin, vaan viittä tai kymmentä pistettä (5-fold crossvalidation ja 10-fold crossvalidation). Käytettäessä viittä tai kymmentä pistettä virhearvio on vähemmän pessimistinen. Leave One Out -menetelmä mahdollistaa mallin toimivuuden myös muillakin aineistolla (Venables ym. 2002).

3.1.1 Lineaarinen diskriminanttialyysi (LDA)

Kokeilin työssäni lineaarista diskriminanttialyysiä (LDA) mallin laatimiseksi (kaava 1). Diskriminanttialyysissä tarkastellaan havaintoaineistoa, joka on jaettu jollain tavoin ryhmiin. Ryhmät voivat perustua diskreetteihin suureisiin tai ne voidaan luoda diskretoimalla jatkuvia suureita. Diskriminanttialyysissä pyritään löytämään parhaat erottelevat muuttujat, eli ne, joiden arvot vaihtelevat eniten eri ryhmiin kuuluvien havaintojen välillä.

Löydettyjen muuttujien avulla haetaan niiden lineaarikombinaationa uusi muuttuja tai indeksi, jonka avulla eri ryhmät pystytään erottamaan toisistaan. Käyttämällä löydettyjä erottelevia muuttujia tai niiden kombinaatiota luodaan lopulta sääntö, jonka avulla uudet havainnot pystytään luokittelemaan johonkin tarkastelluista ryhmistä. Sääntö uusien havaintojen luokitteluun voi perustua ryhmäkohtaisiin luokittelufunktioihin tai diskriminanttifunktioon, jonka saaman arvon perusteella uusi havainto luokitellaan (Sharma 1996).

$$L = a_1x_1 + a_2x_2 + \dots a_px_p + c \quad (1)$$

, missä a_1 on diskriminanttikerroin, x_1 on selittävä muuttuja, p on selittävän muuttujan järjestysnumero ja c vakiotermin.

Diskriminanttialyysi olettaa havaintojen olevan peräisin moniulotteisesta normaalijakaumasta. Mikäli ehto normaalijakautuneisuudesta ei toteudu, se vaikuttaa analyysissä tehtävien tilastollisten testien luotettavuuteen, sekä luokittelutuloksiin. Samaan tapaan luokittelussa käytettävien ryhmien kovarianssimatriisit oletetaan samoiksi, ja mikäli tämä ehto ei toteudu, vaikuttaa sekin analyysin tilastolliseen luotettavuuteen ja luokitteluun (Sharma 1996).

Mikäli kovarianssimatriisit eivät ole samoja, on käytettävä neliöllistä diskriminanttialyysiä (Venables ym. 2002).

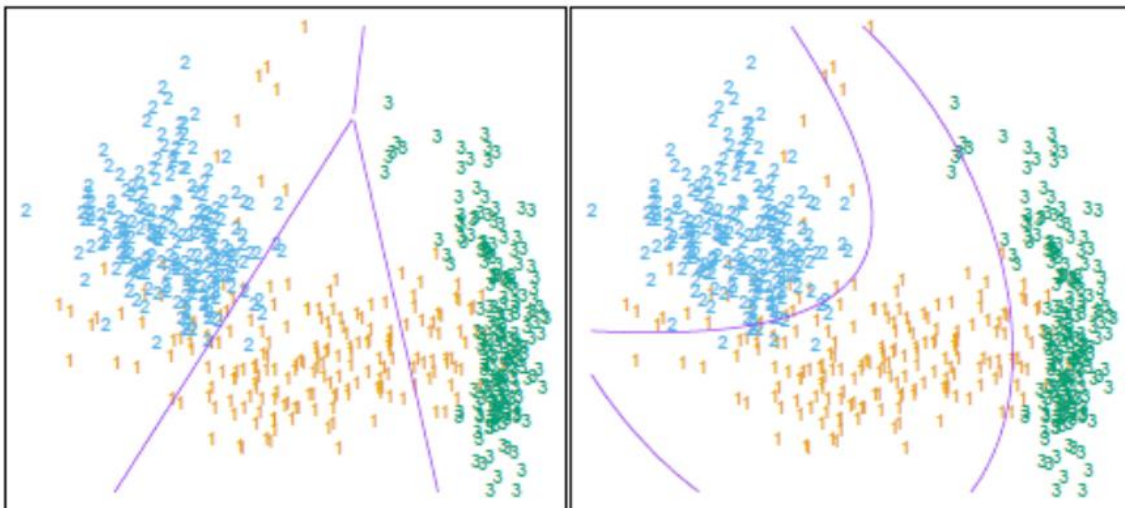
3.1.2 Neliöllinen diskriminanttialyysi (QDA)

Toinen luokittelukeinoni oli käyttää neliöllistä diskriminanttialyysiä QDA:ta (kaava 2) (Quadratic Diskriminant Analysis).

$$\mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{b}^T \mathbf{x} + c \quad (2)$$


, missä A on korkeimman asteen selittävän muuttujan x diskriminanttikerroin, b on pienimmän asteen selittävän muuttujan x diskriminanttikerroin, T on muuttujan aste (potenssi) ja c vakiotermi. Käytännössä termien määrä on rajoittamaton, mutta tilastollisesti ei ole järkevää pitää enempää selittäviä muuttujia kuin on selitettäviä luokkia (Venables ym. 2002). QDA poikkeaa LDA:sta vain korkeamman asteen luokittelufunktion mukaan.

QDA etsii rajapintoja joustavammin, mikä voidaan nähdä kuvasta 9. Kuvassa luokitteluongelma on ratkaistu sekä LDA:n, että QDA:n avulla.



Kuva 9. Lineaarisella diskriminantianalyysillä ja neliöllisellä diskriminantianalyysillä muodostetut luokkien rajat (lähde:http://www.sal.tkk.fi/vanhat_sivut/Opinnot/Mat-2.4142/S2010/esitykset/es7_aira.pdf).

LDA:ta voidaan käyttää luotettavasti selittävien muuttujien hankintaan QDA:ta varten, mutta QDA:ta voidaan käyttää myös itsenäisesti omien muuttujien valintaan. Kuvassa 10 voidaan nähdä, miten vähän poikkeaa LDA:n avulla haettujen, ja QDA:n avulla haettujen luokkien rajat.



Kuva 10. Vasemmanpuoleisessa kuvassa luokkien rajapinta on muodostettu LDA:n muuttujien mukaan. Oikeanpuoleisessa kuvassa rajapinta on muodostettu muuttujilla, jotka on saatu suoraan QDA:n mukaan (lähde: http://www.sal.tkk.fi/vanhat_sivut/Opinnot/Mat-2.4142/S2010/esitykset/es7_aira.pdf).

Kuten kuvasta 10 havaitaan, erot eivät ole suuret muunnettaessa LDA:n avulla etsityt muuttujat QDA:ta varten. QDA:lla saadaan yleensä parempia tuloksia, mutta estimoitavia parametreja on enemmän. Omassa työssäni SPSS -ohjelmalla en pystynyt tekemään QDA:ta vaan ainoastaan LDA:ta, mutta käytin sen antamaa informaatiota muuttujista myös QDA mallien muodostamiseen R:llä.

Muiden luokittelumenetelmien käytöstä en kokenut olevan lisähyötyä mallien laatimisessa (k - lähimmän naapurin menetelmä tai eri päätöspuumenetelmät).

3.2 Mallin tarkastelu

Työssäni on kyseessä luokitteluongelma, joten regressioanalyysille tyypillisten virheestimaattien laskentaa ei voitu soveltaa. Mallin toimivuutta tarkastelin oikeinluokittumisasteen avulla (kaava 3):

$$\text{Oikeinluokitus} - \% = \frac{n.\text{oikein}}{n} \times 100 \quad (3)$$

, missä n.oikein on mallilla oikeinluokittuneiden mikrokuvioiden määrä ja n mikrokuvioiden kokonaismäärä.

Mallin toimivuuden tarkastelemisessa käytin Kappa-arvoa ja Wilksin Lambda-arvoa. Kappa-arvo (κ) kuvaa luokituksen onnistumista verrattuna satunnaiseen luokitteluun, eli se ottaa myös sarake- ja rivisummat (kaava 4):

$$\hat{\kappa} = \frac{n \times \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{n^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (4)$$

, missä r on virhematriisin rivien ja sarakkeiden lukumäärä, x_{i+} on rivisumma rivillä i , x_{+i} on sarakesumma rivillä i , n on havaintojen lukumäärä ja x_{ii} on havaintojen lukumäärä rivillä i ja sarakkeella i . Luokituksen voidaan katsoa onnistuneen hyvin, jos kappia arvo on suurempi kuin 0,4. Mikäli kappia-arvo on suurempi kuin 0,75, luokituksen katsotaan onnistuneen erinomaisesti (Landis ja Kochin, 1977).

Wilksin lambda -arvot vaihtelevat nollan ja ykkösen välillä. Jos ryhmien välillä ei ole lainkaan eroa, lambda saa arvon 1. Jos taas ryhmien välillä on maksimaalinen ero, lambda saa arvon 0. Wilksin Lambda -arvo lasketaan kaavalla 5:

$$\lambda = \frac{\sum f_r + \sum f_c - (F_r + F_c)}{2N - (F_r + F_c)} \quad (5)$$

, f_r on suurin frekvenssi rivimuuttujan r luokassa, f_c on suurin frekvenssi sarakemuuttujan c luokassa, F_r on suurin frekvenssi rivimuuttujan reunajakaumassa, F_c on suurin frekvenssi sarakemuuttujan reunajakaumassa ja N havaintojen lukumäärä. Testi testaa käytännössä lineaaristen kombinaatioiden vaihtelua eli onko luokkien keskiarvojen välillä eroa ennustettaessa luokkia kyseisillä selittävillä muuttujilla. Työssäni laskin arvot käyttäen SPSS:n valmista toimintoa. Lisäksi muuttujaa valitessa kokeilin R:n toimintoa `greedy.wilks`, joka valitsee muuttujia malliin Wilksin lambda -arvon mukaan. (KvantiMOT - Menetelmäopetuksen tietovaranto. Tampere : Yhteiskuntatieteellinen tietoarkisto. <<http://www.fsd.uta.fi/menetelmaopetus/>>. (Viitattu 05.12.2011.)

Lambdasta on myös asymmetrinen versio, jossa täytyy määritellä, kumpi muuttuja on selittäjä ja kumpi selitettävä. Kaavaksi (kaava 6) muodostuu tällöin:

$$\lambda = \frac{\sum f_i - F_d}{N - F_d} \quad (6)$$

, missä f_i suurin frekvenssi selittävän luokan muuttujassa i F_d on suurin frekvenssi selittävän muuttujan reunajakaumassa d ja N havaintojen lukumäärä.

Muuttujien välistä korrelaatiota tarkastelin SPSS:n avulla. Muuttujien välinen korrelaatio lasketaan kaavalla 7.

$$\rho_{X,Y} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{E((X - \mu_X)(Y - \mu_Y))}{\sigma_X \sigma_Y} \quad (7)$$

, missä μ_X ja μ_Y ovat muuttujien X ja Y odotusarvot sekä σ_X ja σ_Y ovat muuttujien X ja Y keskihajonnat. Korrelaatio ei kerro suoraan mallin kausaalisuutta eli syy-seuraus-suhdetta, mutta sen avulla saadaan viitteitä siitä, kuinka riippumattomia muuttujat ovat toisistaan.

4. Tulokset

Työssäni tarkastelin eri muuttujien merkitsevyyksiä R -ohjelman toimintojen stepclass (vaiheittainen muuttujavalintatyökalu luokitteluongelmaan, joka käyttää valittua luokittelufunktiota, kuten LDA ja QDA), stepAIC (stepwise model selection by exact An Information Criterion) ja greedy.wilks (stepwise model selection by Wilk's Lambda criterion) avulla. Merkitsevyydestien tulosten perusteella rajasin muuttujat 61 kappaleeseen. Näistä 61 muuttujasta kokeilin oman ohjelmani avulla kaikki mahdolliset 3 selittäjän ja 4 selittäjän yhdistelmät. Ohjelmani on muunnos tutkija Inka Pippurin ohjelmasta. Ohjelma myös laski automaattisesti kyseisten mallien oikeinluokitusasteen sekä kappa-arvon.

4.1 Objektiviseen luokitteluun perustuvat mallit

Hieman yllättäen neljä selittävää muuttujaa ei tuonut enää lisäarvoa mallille, ja lisäksi neljän selittävän muuttujan tapauksessa riskinä oli mallin ylioppiminen ja muuttujien korreloituminen liikaa keskenään. Näiden tutkimusten perusteella päätin laatia mallin käyttämällä ainoastaan kolmea selittävää muuttujaa (kaavat 8, 9 ja 10). Lopullinen kolmen selittäjän luokittelumalli sai muodon:

$$\text{Malli 1 (2 selitettävää luokkaa)} = \text{lda} (\mathbf{l_p5} + \mathbf{l_p20} + \mathbf{l_havg}) \quad (8)$$

$$\text{Malli 2 (3 selitettävää luokkaa)} = \text{qda} (\log \mathbf{f_h20} + \log \mathbf{f_h40} + (\mathbf{l_h5})^2) \quad (9)$$

$$\text{Malli 3 (4 selitettävää luokkaa)} = \text{qda} (\mathbf{l_h5} + \log \mathbf{f_h20} + (1/\mathbf{f_h60})) \quad (10)$$

Ainoastaan kahden selittävän luokan tapauksessa LDA osoittautui paremmaksi kuin QDA. Tämä johtunee siitä, että kahden selittävän luokan tapauksessa ongelma on yksinkertaisempi ja rajafunktion piirtyminen voi olla sattumalta parempi, vaikka kyseessä olisikin normaali ensimmäisen asteen yhtälö. Mielenkiintoista oli myös havaita, että samat muuttujat valikoituivat kolmen ja neljän selittävän luokan tapauksissa, tosin hieman eri muunnoksina. Muuttujat, jotka valikoituivat lopullisiin malleihin, vastaavat osittain myös omia odotuksiani. Pidän etenkin tärkeänä alemman pituusluokan ($f/l_{h5} - f/l_{h60}$) tunnuksia, sillä ne kuvastivat mielestäni

mahdollisuutta suuresta määrästä aliskasvosta sekä lisävaltapuita. Myös vastaavien pituusluokkien intensiteetti-arvot oletin merkitseviksi.

Mallien oikeenluokittuminen voidaan nähdä taulukosta 7.

Taulukko 7. Mallilla ennustettujen ja todellisen tilanteen (objektiivinen luokittelu) väliset erot

Todellinen Tilanne		Mallilla Ennustetut				
MALLI 1		Tarve	Ei hoitotarvetta	Yht.		
	Tarve	74	2	76		
	Ei hoitotarvetta	14	14	28		
	Yhteensä	88	16	104		
MALLI 2		Energiapuukohteet	Taimikonhoitokohteet	Ei hoitotarvetta	Yht.	
	Energiapuukohteet	34	0	0	34	
	Taimikonhoitokohteet	5	34	4	43	
	Ei hoitotarvetta	9	6	12	27	
	Yhteensä	48	40	16	104	
MALLI 3		Energiapuukohteet	Ennakkoraivaus	Taimikonhoitokohteet	Ei hoitotarvetta	Yht.
	Energiapuukohteet	9	4	0	0	13
	Ennakkoraivaus	1	20	0	0	21
	Taimikonhoitokohteet	1	3	36	3	43
	Ei hoitotarvetta	2	7	8	10	27
	Yhteensä	13	34	44	13	104

Kuten taulukosta 7 nähdään, etenkin energiapuukohteet luokituvat erittäinkin hyvin. Neljän luokan tapauksessa energiapuukohteet sekoittuvat hieman ennakkoraivausta vaativien kohteiden kanssa, mutta tätä en pidä niin pahana ongelmana, sillä kohteilla on paljon samanlaisia piirteitä. Myös taimikonhoitokohteiden voidaan sanoa luokittuvan tarkasti, mutta sen sijaan Ei hoitotarvetta vaativat -kohteet luokituvat melko heikosti. Uskoisin sen johtuvan siitä, että kyseisillä kohteilla on melko vähän yhteisiä piirteitä, sillä ne koostuvat sekaisin taimikoista ja nuorista kasvatusmetsistä. Mikäli aineisto olisi ollut isompi, olisin voinut kokeilla jakaa Ei hoitotarvetta vaativat -kohteet myös kahteen erillään olevaan luokkaan kehitysluokan mukaisesti. Kahden luokan tapauksessa varsinaiset hoitokohteet löytyvät erittäin hyvin. Hieman kuvaavamman mallin toimimisesta saadaan oikeinluokittumisasteen avulla (taulukko 8).

Taulukko 8. Oikeinluokittumisen onnistuminen prosentteina sekä kappa-arvot malleille

Malli 1	
Oikeinluokittumisaste (kaikki)	84,62 %
Oikeinluokittumisaste hoitotarvetta vaativille	97,37 %
Oikeinluokittumisaste Ei hoitotarvetta vaativille	50,00 %
Kappa-arvo	0,525
Malli 2	
Oikeinluokittumisaste (kaikki)	76,92 %
Oikeinluokittumisaste energiapuukohteille	100,00 %
Oikeinluokittumisaste taimikonhoitokohteille	79,07 %
Oikeinluokittumisaste Ei hoitotarvetta vaativille	44,44 %
Oikeinluokittumisaste hoitokohteille (Energia+Taimi)	88,31 %
Kappa-arvo	0,645
Malli 3	
Oikeinluokittumisaste (kaikki)	72,12 %
Oikeinluokittumisaste energiapuukohteille	69,23 %
Oikeinluokittumisaste ennakkoraivauskohteille	95,24 %
Oikeinluokittumisaste taimikonhoitokohteille	83,72 %
Oikeinluokittumisaste Ei hoitotarvetta vaativille	37,04 %
Oikeinluokittumisaste hoitokohteille (Energia+Taimi)	84,42 %
Kappa-arvo	0,572

Kappa-arvot olivat yli 0,5, mikä tarkoittaa, että luokitus oli yli 50 % parempi kuin satunnainen luokitus. Oikeinluokittumisprosentista on havaittavissa, että mallit toimivat varsin hyvin, vaikka Ei hoitotarvetta -kohteet luokituvatkin erittäin huonosti. Tämä huonontaa myös kappa-arvoa. Tärkeämpänä kuin mallin kykyä paikantaa Ei hoitotarvetta -kohteita, pidän mallin toimivuutta eroteltaessa taimikonhoitokohteita ja energiapuukohteita toisistaan sekä Ei hoitotarvetta -kohteista. Lisättäessä ennakkoraivauskohteet oikeinluokitusprosentti energiapuukohteiden osalta laskee melko paljon, joten useamman luokan tapauksessa hoitotarpeen luokittuminen on epävarmempaa.

Myös selittävien muuttujien Wilksin lambdan arvot olivat 5 %:n hyväksymistasolla hyväksyttävät (taulukko 9).

Taulukko 9. Wilksin Lambdan arvot muuttujille**Ryhmäkeskiarvojen yhdenvertaisuus –testi****Malli 1**

	Wilksin lambda	F	df1	df2	Merkitsevyys
f_p5	,918	9,147	1	102	,003
f_p20	,895	11,910	1	102	,001
l_havg	,899	11,421	1	102	,001

Malli 2

	Wilksin lambda	F	df1	df2	Merkitsevyys
log f_h20	,611	32,171	2	101	,000
log f_h40	,642	28,197	2	101	,000
(l_h5)^2	,791	13,346	2	101	,000

Malli 3

	Wilksin lambda	F	df1	df2	Merkitsevyys
l_h5	,456	39,814	3	100	,000
log f_h20	,609	21,428	3	100	,000
(1/f_h60)	,853	5,766	3	100	,001

Lambda-arvoista voi todeta, että muuttujien välillä on eroa riittävästi ja kyseisten muuttujien avulla on mahdollista saada hoitotoimenpideryhmät luokiteltua erilleen eli työssäni käytettävien

luokkien luokkakeskusten välille saadaan riittävästi eroa. Kaikki mallit ovat siis muuttujien osalta hyväksyttävissä 5 %:n hyväksymistason mukaan.

Myös luokittelufunktio(ide)n selitettävyys voitiin laskea SPSS:n avulla (taulukko 10).

Taulukko 10. Wilksin lambdan asymptinen versio

Wilksin lambda: Malli 1

Testi funktio	Wilksin lambda	Chi-square	Df	Merkitsevyys
1 / 1	,835	18,094	3	,000

Wilksin lambda: Malli 2


Testi funktiot	Wilksin lambda	Chi-square	Df	Merkitsevyys
1 / 2	,529	63,635	6	,000
2 / 2	,942	5,943	2	,051

Wilksin lambda: Malli 3

Testi funktiot	Wilksin lambda	Chi-square	Df	Merkitsevyys
1 / 3	,321	112,938	9	,000
2 / 3	,745	29,237	4	,000
3 / 3	,959	4,128	1	,042

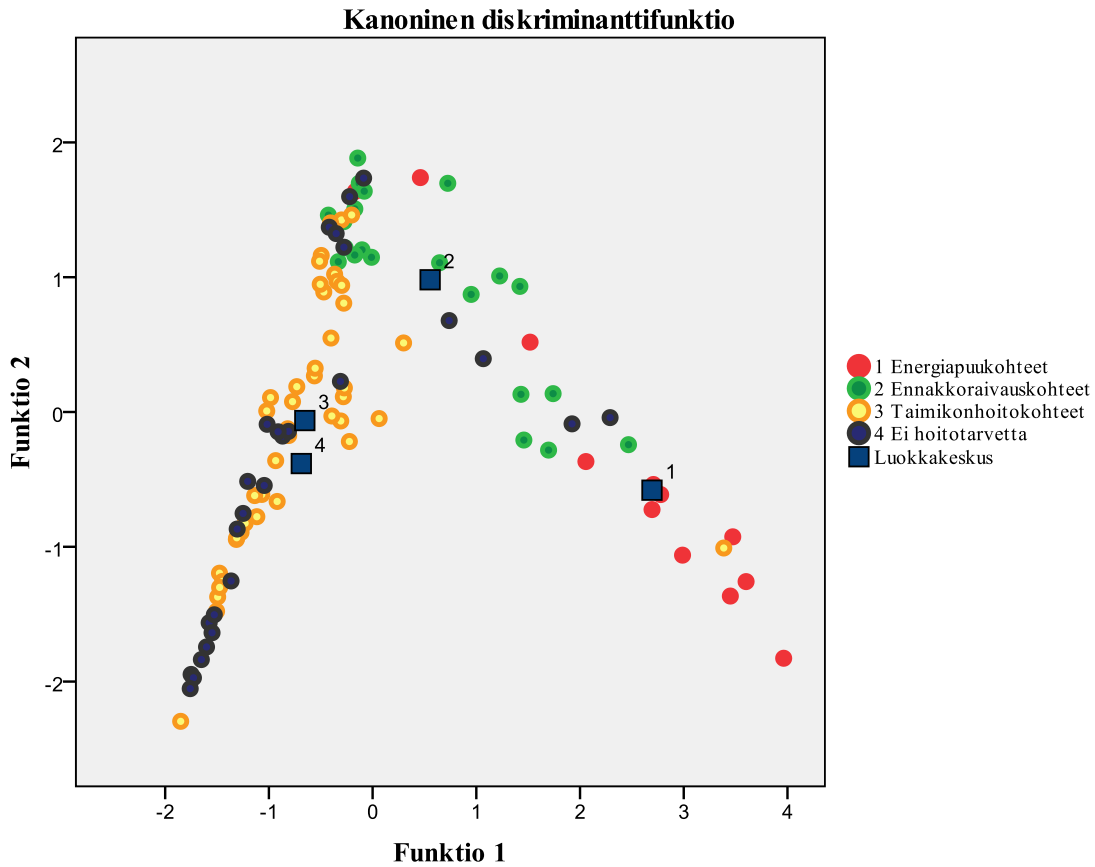
Kuten taulukosta 10 havaitaan, testifunktiot löytävät luokkien välille eroa riittävästi, mutta malli 3:n testifunktio 2/2:n tapauksessa hyväksymistasoa on nostettu 5,1 prosenttiin. Wilksin lambda arvojen perusteella voidaankin todeta mallin olevan melko hyvin toimiva. Lisäksi päätin havainnollistaa luokkien jakautumista ja luokkakeskusten sijaintia tekemällä SPSS:n avulla kuvaajat malleille 2 ja 3 (kuva 12 ja kuva 13).

Kanoniset diskriminanttifunktiot



Kuva 12. Luokkakeskusten sijainnit laskettuna LDA:n avulla (malli 2)

Kuten kuvasta 12 huomataan, on luokkien luokkakeskusten välillä eroa. Etenkin taimikoiden ja energiapuukohteiden luokkakeskusten välillä olisi hyvä olla selkeä ero, joten voidaan todeta, että malli toimii myös tämän asian osalta hyvin. Ei hoitotarvetta -kohteiden luokittuminen olisi silti samansuuntainen kuin LDA:n tapauksessa.



Kuva 13. Luokkakeskusten sijainnit laskettuna LDA:n avulla (malli 3)

Neljän luokan tapauksessa saadaan myös tärkeimpien luokkien 1–3 välille riittävästi eroa. Ei hoitotarvetta vaativien kohteiden sijainti kuvassa on hyvin pirstaleinen, mikä kuvastaa kyseisen luokan heikkoa luokittumista. Muiden osalta pääsääntöisesti kohteet ovat luokkakeskuksen lähellä. Silti mielestäni neljän luokan tapauksessa tulos voisi olla parempikin. Tärkeää on havaita molemmista kuvista (13 ja 14), että luokkakeskusten välisten erojen lisäksi kohteiden etäisyydet omasta luokasta eivät ole kovinkaan isoja. Tämä kuvaa hyvin onnistunutta luokitusta: luokkien välillä on suuret erot, mutta luokan sisällä etäisyydet ovat pienet.

4.2 Maastopohjaiseen luokitukseen pohjautuvat mallit

Maastokatselmuksen yhteydessä keräsin subjektiivisen arvion mikrokuvioiden hoitotarpeesta. Kokeilin laatia mallia, jossa luokkia olisi kaksi (kaava 11) ja toisessa luokkia vastaavasti kolme (kaava 12). Molemmissa tapauksissa käytin kolmea selittäjää mallin muodostamisessa vastaamaan kyseisiä luokituksia.

$$\text{Maasto 2} = qda (l_{veg})^2 + (l_{p60})^2 + (1/l_{p60}) \quad (11)$$

$$\text{Maasto 3} = qda (f_{h40} + l_{havg} + l_{h40}) \quad (12)$$

Maastossa luokituksen oikeinluokittumisprosentti kohosi myös melko korkealle. Taulukossa 11 on esiteltyä molempien mallien luokittuminen numeerisesti.

Taulukko 11. Maastossa suoritetun luokituksen vertaaminen mallilla ennustettuun

Todellinen Tilanne		Mallilla Ennustetut		
MAASTO 2	Tarve	Ei hoitotarvetta	Yhteensä	
Tarve	25	12	37	
Ei hoitotarvetta	5	62	67	
Yhteensä	30	74	104	
			Ei	
MAASTO 3	Energiapuukohteet	Taimikonhoitokohteet	hoitotarvetta	Yhteensä
Energiapuukohteet	8	0	5	13
Taimikonhoitokohteet	0	23	1	24
Ei hoitotarvetta	4	6	57	67
Yhteensä	12	29	63	104

Kuten taulukoista havaitaan, myös ”Ei hoitotarvetta vaativien” -kohteiden luokittelu onnistui hyvin. Myös kappa-arvot olivat hyvät eli molemmissa tapauksissa yli 0,6 (taulukko 12). Maastoarvion heikkoutena on sen pohjautuminen subjektiiviseen näkemykseen. Toisaalta myös normaalissa maastomittauksiin perustuvassa metsäsuunnittelussa päätöksenteko toimenpiteestä tapahtuu maastossa, joten oli mielenkiintoista nähdä, miten subjektiivinen ja objektiivinen luokittelu eroavat ja miten mallinnus lasertunnuksilla niille onnistuisi. Maastopohjaiseen luokitukseen pohjautuvien mallien ongelmana näkyy myös talven ja kevään aikana tehdyt hoitotoimenpiteet, jotka näkyvät maastossa mutta eivät laserkeilaustunnuksista. Tällaisia kohteita

oli muutama mukana, mikä hieman heikentää oikeinluokitusta, sillä virheellisesti merkitsin kyseiset kohteet Ei-tarvetta luokkaan ilman erityistä huomiota, että kyseisellä kohteella oli tehty kevään aikana hoitotoimenpide. Tämä näkyy etenkin oikeinluokittumisprosentissa energiapuukohteiden osalta (taulukko 12).

Taulukko 12. Oikeinluokittumisprosentit maastopohjaiselle luokitukselle ennustettaessa mallilla

Maasto 2	
Oikeinluokittumisaste (kaikki)	83,65 %
Oikeinluokittumisaste hoitotarvetta vaativille	67,57 %
Oikeinluokittumisaste Ei hoitotarvetta vaativille	92,54 %
Kappa-arvo	0,628
Maasto 3	
Oikeinluokittumisaste (kaikki)	84,62 %
Oikeinluokittumisaste energiapuukohteille	61,54 %
Oikeinluokittumisaste taimikonhoitokohteille	95,83 %
Oikeinluokittumisaste Ei hoitotarvetta vaativille	85,07 %
Oikeinluokittumisaste hoitokohdeille (Energia+Taimi)	83,78 %
Kappa-arvo	0,690

Kuten taulukosta 12 huomataan, Ei hoitotarvetta -kohteiden luokittuminen on onnistunut paremmin kuin objektiiviseen luokitteluun perustuvassa mallissa.

Tein myös muuttujien lambda-arvoja koskevat testit tarkastellakseni muuttujien hyvyyttä mallien laatimiseksi (taulukko 13).

Taulukko 13. Wilksin Lambda -arvot mallien muuttujille**Maasto 2**

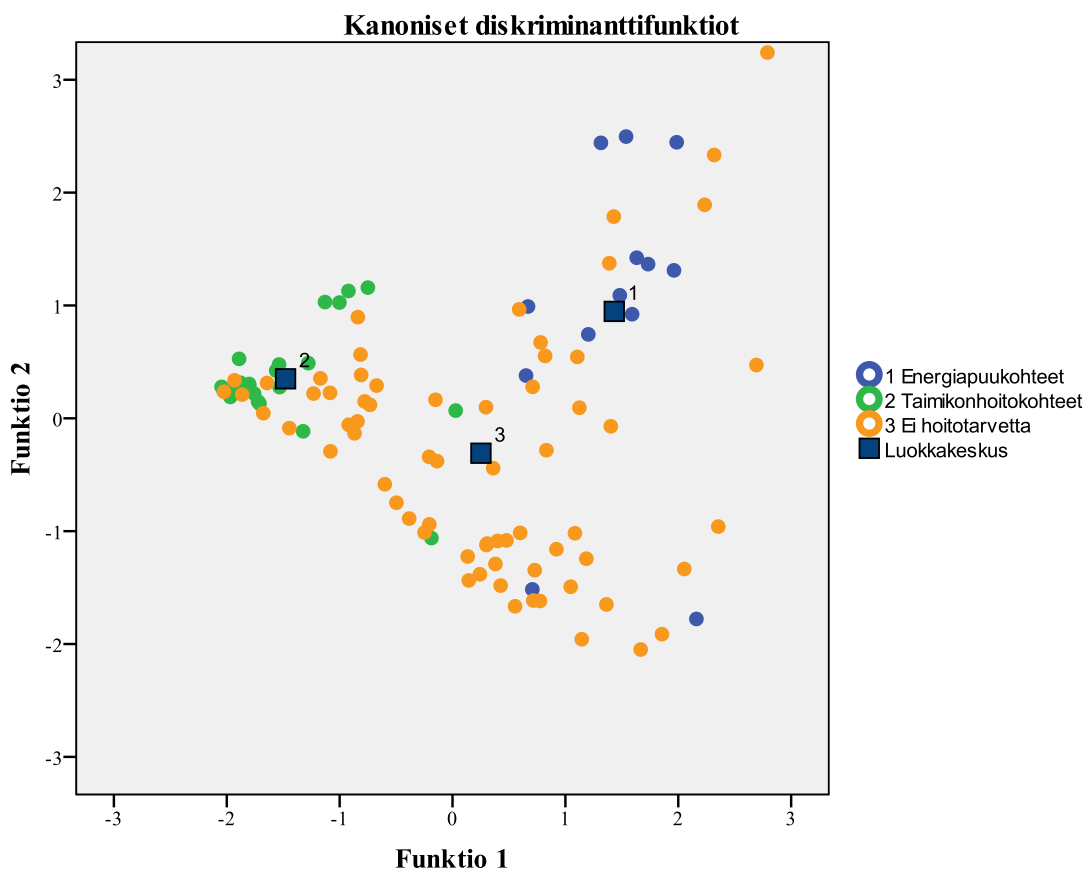
	Wilksin lambda	F	df1	df2	Merkitsevyys
$(l_{veg})^2$,948	5,589	1	102	,020
$(l_{p60})^2$,882	13,651	1	102	,000
$(1/l_{p60})$,878	14,188	1	102	,000

Maasto 3

	Wilksin lambda	F	df1	df2	Merkitsevyys
l_{havg}	,671	24,784	2	101	,000
l_{h40}	,648	27,389	2	101	,000
f_{h40}	,554	40,617	2	101	,000

Kuten taulukosta 13 voidaan havaita, ovat kaikki muuttujat molemmille malleille 5%:n hyväksymistasolla merkitseviä. Korkeat muuttujien lambda-arvot kertovat myös mallien mahdollisuudesta toimia hyvin eli tuoda selkeästi eroa luokkien välille. Lisäksi luokittelufunktion analyysit osoittivat, että luokittelut onnistuivat hyvin (LIITE: Lisätaulukot).

Varsin korkeat lambda-arvot voidaan havaita myös luokkakeskusten etäisyyksissä. Sen sijaan verrattaessa objektiiviseen luokitteluun perustuviin malleihin voi havaita, että luokkien sisällä erot luokkakeskukseen ovat hieman isommat mutta ne eivät ole merkittävästi isommat (kuva 14).



Kuva 14. Luokkakeskusten sijainnit laskettuna LDA:n avulla maastopohjaiselle kolmen luokan mallille

Huomioitavaa on myös kuvasta 14, että QDA:n mukaisella rajapintojen haulla päästään hieman vielä parempaan luokitustulokseen.

4.3 Ajoituksen tutkiminen

Työssäni oli myös tarkoitus selvittää, miten toimenpiteen lisäksi olisi mahdollista päästä kiinni hoitotoimenpiteen ajoitukseen. Maastotöiden aikana tein subjektiivisen arvion kuvion hoitotarpeen lisäksi myös hoitotarpeen ajoittamisesta. Työssäni toimenpidetarve heti tarkoittaa, että toimenpide tulee tehdä seuraavan kolmen vuoden aikana. Hoitotoimenpiteen ajoituksen ollessa myöhemmin, hoitotoimenpide on tehtävä 3–6 vuoden sisällä. Kohteet, joissa hoitotoimenpidettä ei ole tarvetta tehdä, ovat kohteita, joissa hoitotoimenpide oli juuri tehty, tai

kohteita, joissa hoitotoimenpide on yli 6 vuoden päässä nykytilasta. Ajoituksen selvittämiseksi on tehty malli (13):

$$\text{Maasto 5 luokka, ajoituskokeilu} = qda (1_p40 + \log(1_h40) + (1_p80)^2) \quad (13)$$

Tein myös samaiset SPSS- ja R-ohjelmien avulla lasketut tarkastelut kuin objektiivisille ja maastopohjaisille malleille. Taulukoissa 14 ja 15 ovat koosteet mallin tarkastelusta.

Taulukko 14. Kohteiden jakautuminen ja oikeinluokittumisprosentti sekä kappa-arvo

Todellinen Tilanne	Mallilla Ennustetut					Yht.
	Energiapuukohteet, heti	Taimikonhoitokohteet, heti	Energiapuukohteet, myöhemmin	Taimikonhoitokohteet, hteet, myöhemmin	Ei hoitotarvetta	
Energiapuukohteet, heti	8	0	5	0	0	13
Taimikonhoitokohteet, heti	0	22	0	0	2	24
Energiapuukohteet, myöhemmin	2	0	31	0	1	34
Taimikonhoitokohteet, myöhemmin	0	4	0	5	2	11
Ei hoitotarvetta	1	2	7	2	10	22
Yhteensä	11	28	43	7	15	104
Oikeinluokittumisaste (kaikki)		73.08 %				
Oikeinluokittumisaste energiapuukohteille (heti)		61.54 %				
Oikeinluokittumisaste Taimikonhoitokohteille (heti)		91.67 %				
Oikeinluokittumisaste energiapuukohteille (myöh.)		91 %				
Oikeinluokittumisaste Taimikonhoitokohteille (myöh.)		45 %				
Oikeinluokittumisaste Ei hoitotarvetta vaativille		45.45 %				
Oikeinluokittumisaste hoitokohdeille (Energia+Taimi), heti		81.08 %				
Kappa-arvo		0.604				

Kuten taulukosta 14 voidaan huomata, on luokittelu onnistunut lähtökohtaan nähden melko hyvin taimikoiden osalta. Mallilla on vaikea selvittää hoitokiireellisyys, joka aiheutuu pituuden eroavaisuuksista taimikoissa. Maastossa tämä kilpailutilanne pituuden osalta on helpompi huomata ja hyvin yksinkertaista verrattaessa sen mallintamista – saati sitten luomalla malli lasertunnuksista, joka ottaisi tämän asian huomioon. Positiivista on myös energiapuukohteiden melko hyvä luokittuminen sekä energiapuukohteiden ja taimikonhoitokohteiden erottuminen toisistaan erittäinkin hyvin. Kappa-arvo on myös hyvä, joten uskoisin, että hieman paremmalla maastoaineistolla voitaisiin ajoitukseen päästä kiinni vielä paremmin. Tutkin myös mallin muuttujia ja niiden soveltuvuutta sekä luokittelufunktioiden hyvyyttä (taulukko 15).

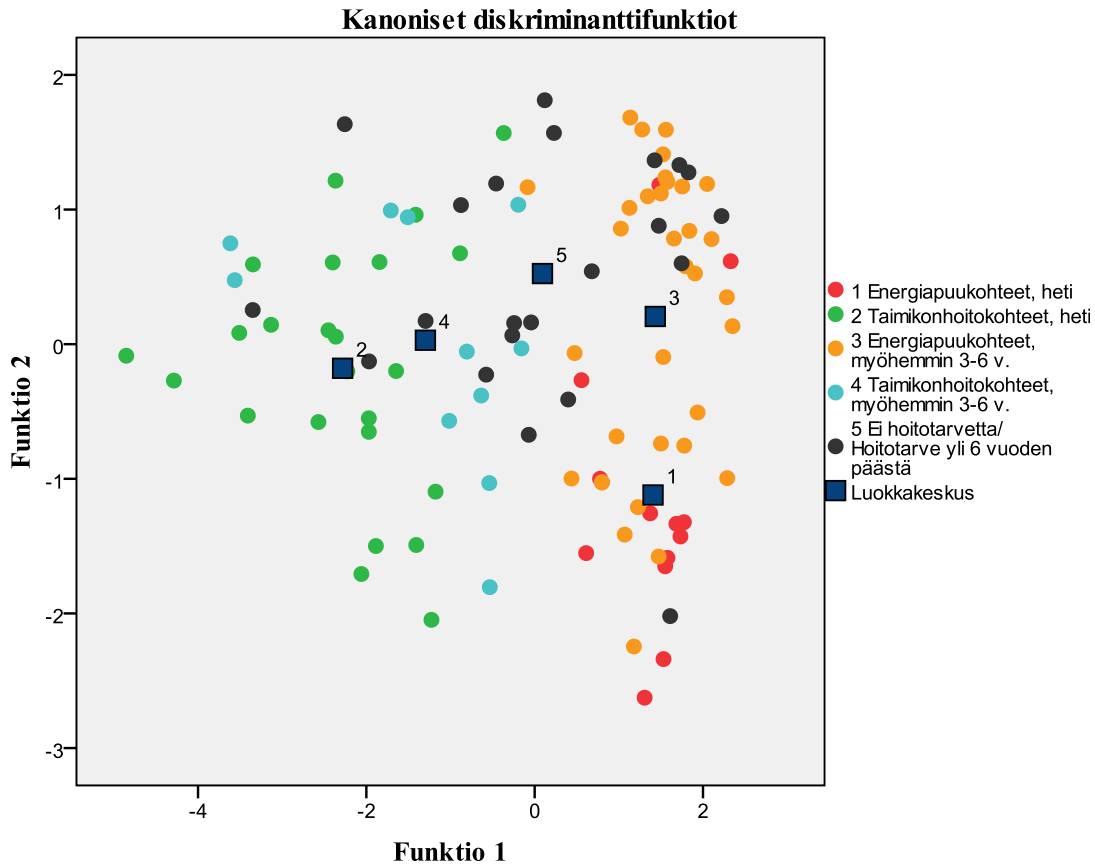
Taulukko 15. Wilksin lambda -arvot mallin muuttujille sekä Wilksin lambdan asymptinen versio**Maasto 5 muuttujien lambda-arvot**

	Wilksin lambda	F	df1	df2	Merkitsevyys
l_p40	,793	6,474	4	99	,000
log (f_h40)	,358	44,399	4	99	,000
(l_p80) ²	,792	6,490	4	99	,000

Wilksin lambda funktioille

Testifunktiot	Wilksin lambda	Chi-square	Df	Merkitsevyys
1 / 3	,232	144,632	12	,000
2 / 3	,793	22,988	6	,001
3 / 3	,990	1,031	2	,597

Muuttujien osalta lambda-arvot ovat hyvät ja merkitsevät, mutta luokittelufunktion viimeisen testifunktion osalta merkitsevyydestä ylittää 5 %:n hyväksymisrajan. Muuttujien korkeat Lambda-arvot näkyvät hyvin myös luokkien välisten luokkakeskusten etäisyyksistä (kuva 15).



Kuva 15. Luokkakeskusten sijainnit laskettuna LDA:n avulla ajoituksen tutkimiseksi

Kuvasta 15 voidaan myös hyvin nähdä, miten energiapuukohteet ja taimikonhoitokohteet erottuvat toisistaan. Ei hoitotarvetta -kohteiden osalta kuvio on melko hajaantunut, kuten olettaa saattoi.

Mielestäni tulokset ovat varsin rohkaisevia myös ajoituksen osalta sekä samansuuruisia kuin aiemmissa tutkimuksissa, jotka pohjautuvat ajoituksen määrittämiseen (Närhi 2006).

5. Diskussio

Verrattaessa aiempiin Närhen (2006), Halvarssonin (2008), Kotamaan (2010), Räsäsen(2010) ja Vastarannan (2011) tutkimuksiin on tulokseni hyvin samaa tasoa. Kuten aiemmin mainitsin, Närhen tutkimuksessa oikeinluokitus oli 0,69–0,72 ja kappa-arvo 0,34–0,54. Halvarssonin tutkimuksessa ennustettiin harvennustarvetta perustuen metsäntiheysindeksiin, joka perustui laserpisteisiin kuviolta. Kyseisen mallin selityssaste oli 0,9. Kotamaan tutkimuksessa, jossa ennustettiin harvennustarvetta nuorissa kasvatusmetsissä kuviokohtaisen läpimitan mukaan, joka oli johdettu laserpisteistä, harvennustarpeen oikeinluokitus oli 0,75 ja kappa-arvo 0,61. Räsäsen tutkimuksessa ennustaessa harvennustarvetta lasermuuttujilla, korkeusmallista lasketuilla tekstuureilla ja maisemamuuttujilla, oikeinluokittumisessa oli jopa 0.98 kappa-arvon ollessa 0.77. Vastarannan tutkimuksessa ennustettiin harvennustarvetta vanhoihin kasvatusmetsiin. Tutkimuksessa logistisen regression avulla päästiin 0,79–0,83 ja k-lähimmän naapurin menetelmällä 0,70–0,86. Laserkeilausperusteista inventointia voidaan siis pitää toimivana työkaluna myös toimenpide-ehdotusten laatimiseen. On huomattava, että myös maastotarkistaminen aiheuttaa hajontaa toimenpidetarpeen määrittämisessä eri henkilöiden kesken.

Työstä on mahdollista tehdä jatkotutkimus käyttäen laajempaa aineistoa ja paneutua myös varttuneisiin metsiköihin. Käyttäen löytämiäni selittäviä lasertunnuksia voidaan ohjelmoida helposti ohjelma, joka käyttää kyseisiä tunnuksia ja hakee energiapuukohteet sekä ehdottaa automaattisesti toteutusajankohdan metsikön pituuden mukaan. Tutkimuksen tuloksia on mahdollista soveltaa energiapuukohteiden sekä taimikonhoidon rästikohteiden löytämiseen sekä hoitotoimenpiteiden suunnitteluun sekä toteutuksen ajoittamiseen. Maastotöiden mittauksia voidaan nyt jo käyttää kontrollina Blomille puustotulkinnan onnistumisesta taimikoille ja nuorille kasvatusmetsiköille. Mielenkiintoista olisi myös kokeilla, onko mahdollista rakentaa mallia, joka ottaisi huomioon kaikki metsänhoidolliset toimenpiteet ja kuinka hyvin se toimisi. Vaihtoehtoisesti voisi myös pilkkoa ongelma pienemmäksi rakentamalla mallia, joka palauttaa pelkästään yhden hoitotoimenpiteen kohteet ja kokeilla näiden useiden yksittäisten mallien toimimista yhdelle metsäsuunnittelualueelle.

Parannettavaa

Blomin tekemä puustotulkinta oli vielä vuonna 2009 sen verran epätarkka, että kohteiden ennakkohaku ei onnistunut. Työni avulla kuitenkin sekä UPM että Blom saivat arvokasta palautetta puustotulkinnan puutteista. Myös mahdollisuus käyttää laajempaa aineistoa sekä tiheämpipulssista laseraineistoa voisi tarkentaa tulosten laatua, sillä tiheään kasvavissa metsissä laserpulssien määrän on oltava suurempi, jotta voidaan varmistaa, että riittävä määrä pulsseja läpäisee tiheän latvuston ja osuu myös lisävaltapuihin, aliskasvokseen ja maahan. Osaksi ei hoitotarvetta vaativat -kohteet eivät luokittuneet yhtä tarkasti kuin varsinaiset hoitotoimenpidettä vaativat kohteet. Tämä selittyy osaksi sillä, että osan kohteista, jotka mittasin, oli juuri maastokauden alussa hoidettu, joten mittaamani puustotieto ei vastannutkaan enää laserpisteparven avulla mallinnettua. Aineistoni olisi voinut olla huomattavasti laajempi, jotta osa kohteista olisi voinut jättää varsinaisen mallin testiaineistoksi. Työn muuttujien valintaa on vaikea tehdä tarkemmin, sillä selittävien muuttujien eri muunnokset ja yhdistelmien muodostamiset ovat nykyisille koneille raskaita suorittaa. Mielestäni tutkin hyvin ja monipuolisesti eri mahdollisuuksia, miten aineistoa tulisi lähestyä ja miten muuttujia voi valita vastaavanlaisiin ongelmiin. Suuremmalla aineistolla sekä kokeilemalla mallia testiaineistoon saataisiin tutkimuksesta huomattavasti luotettavampi.

Aineiston kokoa enemmän vaikuttaa aineiston valinta. Kun laserkeilausperusteiseen inventointiin erikoistunut yhtiö tekee inventoinnin valitulle alueelle, niin koealat sijoitetaan siten, että ne kattavat alueen vaihtelun mahdollisimman hyvin. Käytännössä tämä tarkoittaa myös sitä, ettei siihen aineistoon tule riittävästi tällaisia kohteita, joita minulla oli tässä työssä. Käsitykseni mukaan taimikoiden ja nuorten kasvatusmetsien luokittelu vaatii oman maastoaineistonsa – ainakin jos pyritään niin hyvään tarkkuuteen kuin mahdollista. Tulevaisuudessa, kun teknologia halpenee, laserkeilausta tullaan uskoakseni käyttämään yhä yleisimmin metsäsovelluksissa ja etenkin metsäsuunnittelussa.

Kirjallisuus

- Brandtberg, T., Warner, T., Landenberger, R. & McGraw, J. 2003. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America. *Remote Sensing of Environment* 85: 290-303.
- Drake, J.B., Dubayah, R.O., Knox, R.G., Clark, D.B. & Blair, J.B. 2002. Sensitivity of large-footprint lidar to canopy structure and biomass in a neotropical rainforest. *Remote Sensing of Environment* 91: 378 – 392.
- Eid, T., Gobakken, T. & Naesset, E. 2004. Comparing stand inventories based on photointerpretation and laser scanning by means of costs-plus-loss analyses. *Scandinavian Journal of Forest Research* 19: 512-523.
- Huuskonen, S., Ojansuu, R., Hynynen, J. Ensiharvennuksen toteutuksen vaikutus metsikön tuotokseen ja tuottoon. *Metsähallituksen metsätalouden julkaisuja* 53, 2004. 62 s.
- Hyyppä J. & Inkinen M. 1999. Detecting and estimating attributes for single trees using laser scanner. *The photogrammetric Journal of Finland* 16 (2): 27-42
- Juntunen, R. 2006. Puustotiedon laadun vaikutus metsänkäsittelyn optimoinnin tuloksiin. Helsingin Yliopiston Maa- ja metsätieteellisen tiedekunnan Pro gradu -työ
- Karppinen, H. & Ahlberg, M. 2008. Metsänomistajakunnan rakenne 2020: Yleiseen väestömuutokseen perustuvat ennustemallit. *Metsätieteen aikakauskirja* 1/2008: 17–32.
- Korhonen, K.T., Ihalainen, A., Miina, J., Saksa, T. & Viiri, H. 2010. Metsänuudistamisen tila Suomessa VMI10:n aineistojen perusteella. *Metsätieteen aikakauskirja* 4/2010: 425-478
- Kotamaa, E., Tokola, T., Maltamo, M., Packalén, P., Kurttila, M. and Mäkinen, A. 2010 Integration of remote sensing-based bioenergy inventory and optimal bucking for stand-level decision making. *Eur. J. For. Res.* **129**, sivut 875–886.

Kärkkäinen, M. 2003. Puutieteen perusteet. Metsäkustannus. 451 s.

Landis, R.J. & Koch, G.G. 1977. The measurement of observer agreement for categorical data. *Biometrics* 33: 159–174.

Lim, K., Treitz, P., Baldwin, K., Morrison, I. & Green, J. 2003. Lidar remote sensing of biophysical properties of tolerant northern hardwood forests. *Canadian Journal of Remote Sensing* 29: 648-678.

Lowell, J.L., Jupp, D.S., Culvenor, D.S. & Coopes, N.C., 2003. Using airborne and ground-based ranging lidar to measure canopy structure in Australian forests. *Canadian Journal of Remote Sensing* 29: 607-622.

Magnussem, S. & Boudewyn, P. 1998. Derivation of stand heights from airborne laser scanner data with canopy-based quantile estimators. *Canadian Journal of Forest Research* 28: 1016- 1031.

Maltamo, M., Eerikäinen, K., Packalen, P. & Hyypä J. 2006. Estimation of stem volume using laser scanning based canopy height metrics. *Forestry* 79: 217-229.

Metsäkustannus. 2006. Hyvän metsänhoidon suositukset. Julkaisusarja / Tapio 22/2006. 100 s.

Metsätehon katsaus nro 22, 2006. Ensiharvennuskäytännön voimakas laatuharvennus, Metsäteho Oy

Mehtätalo, L. 2006. Eliminating the effects of overlapping crowns from aerial inventory estimates. *Canadian Journal of Forest Research* 36(7): 1649-1660

Næsset, E., 1997. Estimating timber volume of forest stands using airborne laser scanner data, *Remote Sensing of Environment*, 61: 246-253.

- Næsset, E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedures and field data. *Remote Sensing of Environment* 80: 88-99.
- Næsset, E. 2004. Practical large-scale forest stand inventory using airborne scanning laser. *Scandinavian journal of Forest Research* 19: 164-179
- Næsset, E. 2004. Accuracy of forest inventory using airborne laser-scanning: Evaluating the first Nordic full-scale operational project. *Scandinavian journal of Forest Research* 19: 554-557.
- Næsset, E. & Okland, T. 2002. Estimating tree height and tree crown properties using airborne scanning laser in boreal nature reserve. *Remote Sensing of Environment* 96 (3-4): 453-465.
- Nelson, R., W. Krabill & J. Tonelli, 1988. Estimating forest biomass and volume using airborne laser data, *Remote Sensing of Environment*, 24:247-267.
- Närhi M. 2008. Kuusen taimikoiden inventointi ja taimikonhoidon kiireellisyyden määrittäminen laserkeilauksen ja metsäsuunnitelmätietojen avulla. *Metsätieteen aikakauskirja* 2008 : 1 , s. 5-15
- Packalen, P. 2006. Using airborne laser scanning data and digital aerial photographs to estimate forest growing stock. *Licensiate thesis*. University of Joensuu. 30s.
- 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(3): 328-341.
- S. Sharma. 1996. *Applied Multivariate Techniques*. John Wiley & Sons, New York,
- Solberg, S. Naeset, E. & Bollandsas O.M. 2006. Single tree segmentation using airborne laser scanner data in a structurally heterogeneous spruce forest. *Photogrammetric Engineering & Remote Sensing* 72: 1369- 1378.

Suvanto, A., Maltamo, M., Packalén, P. & Kangas, J. 2005. Kuviokohtaisten puustotunnusten ennustaminen laserkeilauksella. Metsätieteen aikakauskirja 4/2005: 413–428.

Tuomola T. 2006. Numeeriset ilmakuvat taimikon perkaustarpeen määrittämisessä. Metsätehon katsaus 24/2006. 4 s.

UPM-Kymmene Oyj:n toimintaohje, Nuorten metsien kunnostus, Laatuopas: Hyvän laadun kriteerit. 8 s.

Venables, W.N. and Ripley, B.D. 2002 Modern Applied Statistics with S. Statistics and Computing. Springer, New York, 495 s.

Elektroniset lähteet:

Hast Aira, 2010, Optimointiopin seminaari, Systemianalyysin laboratorio, Aalto Yliopiston teknillinen korkeakoulu, http://www.sal.tkk.fi/vanhat_sivut/Opinnot/Mat-2.4142/S2010/esitykset/es7_aira.pdf. Viitattu 5.12.2011

KvantiMOT - Menetelmäopetuksen tietovaranto. Tampere : Yhteiskuntatieteellinen tietoarkisto. <http://www.fsd.uta.fi/menetelmaopetus>. Viitattu 05.12.2011.

Metsätehon verkkojulkaisu korjuun suunnittelusta ja toteutuksesta: http://www.metsateho.fi/uploads/Korjuun_suunnittelu_ja_toteutus_ver02.pdf. viitattu 28.10.2009.

Hyyppä J. Laserkeilaimen käyttö puustotunnusten mittaamisessa:

http://www.fgi.fi/osastot/projektisivut/kk_www_portaali/rswww/lasercase1.html. Viitattu 5.12.2011.

LIITTEET

Lisätaulukot

Taulukko a. Korrelaatiot työssä käytettävien muuttujien välillä

Objektiivinen luokittelu 2 luokkaa

	f_h95	f_p5	(f_p20) ²
Covariance f_h95	14,174	-29,760	-3399,015
f_p5	-29,760	260,965	30539,858
(f_p20) ²	-3399,015	30539,858	3808276,814
Correlation f_h95	1,000	-,489	-,463
f_p5	-,489	1,000	,969
(f_p20) ²	-,463	,969	1,000

Objektiivinen luokittelu 3 luokkaa

	Log(f_h2 0)	Log(f_h4 0)	(l_h5) ²
Kovarianssi Log(f_h20)	,869	,682	,686
Log(f_h40)	,682	,590	,569
(l_h5) ²	,686	,569	15,930
Korrelaatio Log(f_h20)	1,000	,952	,184
Log(f_h40)	,952	1,000	,186
(l_h5) ²	,184	,186	1,000

Objektiivinen luokittelu 4 luokkaa

	l_h5	Log(f_h2 0)	(1/f_h60)
Kovarianssi l_h5	,582	,247	-,061
Log(f_h20)	,247	,875	-,308
(1/f_h60)	-,061	-,308	,198
Korrelaatio l_h5	1,000	,346	-,180
Log(f_h20)	,346	1,000	-,739
(1/f_h60)	-,180	-,739	1,000

Maastopohjainen luokittelu 2 luokkaa

	(l_veg) ²	(l_p60) ²	(1/l_p60)
Kovarianssi (l_veg) ²	1035340,910	-628249,121	,413
(l_p60) ²	-628249,121	473035,099	-,306
(1/l_p60)	,413	-,306	1,995E-7
Korrelaatio (l_veg) ²	1,000	-,898	,908
(l_p60) ²	-,898	1,000	-,995
(1/l_p60)	,908	-,995	1,000

Maastopohjainen luokittelu 3 luokkaa

	l_havg	l_h40	f_h40
Kovarianssi l_havg	,810	1,436	1,220
l_h40	1,436	6,353	4,363
f_h40	1,220	4,363	3,744
Korrelaatio l_havg	1,000	,633	,701
l_h40	,633	1,000	,895
f_h40	,701	,895	1,000

Maastopohjainen luokittelu 5 luokkaa (ajoitus)

	l_p40	Log(f_h40)	(l_p80) ²
Kovarianssi l_p40	33,183	-,763	1740,695
Log(f_h40)	-,763	,336	-60,924
(l_p80) ²	1740,695	-60,924	99284,542
Korrelaatio l_p40	1,000	-,229	,959
Log(f_h40)	-,229	1,000	-,334
(l_p80) ²	,959	-,334	1,000

Taulukko b. Wilksin lambdan asymptinen versio maastopohjaisille malleille**Wilksin lambda: Maasto 2**

Testi funktio	Wilksin lambda	Chi-square	df	Merkitsevyys
1	,827	19,100	3	,000

Wilksin Lambda: Maasto 3

Testi funktiot	Wilksin lambda	Chi-square	df	Merkitsevyys
1 / 2	,453	79,131	6	,000
2 / 2	,828	18,904	2	,000

Muuttujien valinnan helpottamista varten tehty ohjelma

```

class_accuracy <- function( e )      # tällä lasketaan oikeinluokittuminen ja kappa
{
  pra <- sum(diag(e))/sum(e)
  ab <- c( 1:dim(e)[1] )
  for ( i in 1:dim(e)[1] )
  {
    ab[i] <- sum(e[i,])/sum(e)*sum(e[,i])/sum(e)
  }
  pre <- sum(ab)
  k <- ( pra - pre ) / ( 1 - pre )
  list( oa=pra, kappa=k )
}

tulokset <- rep(0,5)  #luodaan tyhjä rivi
auto <- tulokset     #apumuuttuja

for ( i in 2:61 )    #käy läpi jokaisen sarakkeen(muutetaan mm. 2:sta alkaen aina 61
                    #muuttujaan)
{
  for ( j in 2:61 )  #käy läpi jokaisen sarakkeen
  {
    for ( k in 2:61 )
    {
      if ( i != j && i!= k && j!= k )
      {
        #käy läpi jokaisen kolmikon
        sdata <- cbind( Aineisto3[,1], Aineisto3[,i], Aineisto3[,j], Aineisto3[,k] )

        # ottaa niiden nimet esille

```

```

colnames( sdata ) <- colnames(Aineisto3)[c(1,i,j, k)]

sdata <- as.data.frame( sdata )
#print( sdata )
form <- obj_3 ~ .                #sarakkeen nimi, jota erotellaan

#mallin tekeminen, leave-one-out menetelmällä
malli1 <- lda(form, data=sdata, CV=T)
ct <- table(Aineisto3$obj_3, malli1$class)
class_accuracy(ct)
#print(colnames(sdata[2:4]))      # tulostaa muuttujakolmikron nimen
#print(class_accuracy(ct)$oa)
#print(class_accuracy(ct)$kappa)

tulokset[1]<-colnames(sdata[2])
tulokset[2]<-colnames(sdata[3])
tulokset[3]<-colnames(sdata[4])
tulokset[4]<-class_accuracy(ct)$oa
tulokset[5]<-class_accuracy(ct)$kappa

loppu <- rbind(auto, tulokset)
auto <- loppu
}
}
}
}

write.table(auto, "E:/THESIS/UUTTA/3_luok_paras.txt") #Tulostetiedoston nimeäminen

```

R-ohjelman käyttöön liittyvät koodaukset

#Pakettien ajaminen

```
library(MASS)
library(klaR) #Vaatii asentamisen!!
```

#Aineiston syöttäminen

```
Obj_2 <- read.table( "G:/THESIS/UUTTA/VALMIS/Obj_2.txt", header=TRUE, sep="\t" )
Obj_3 <- read.table( "G:/THESIS/UUTTA/VALMIS/Obj_3.txt", header=TRUE, sep="\t" )
Obj_4 <- read.table( "G:/THESIS/UUTTA/VALMIS/Obj_4.txt", header=TRUE, sep="\t" )
Maasto_2 <- read.table( "G:/THESIS/UUTTA/VALMIS/Maasto_2.txt", header=TRUE, sep="\t" )
Maasto_3 <- read.table( "G:/THESIS/UUTTA/VALMIS/Maasto_3.txt", header=TRUE, sep="\t" )
Maasto_5 <- read.table( "G:/THESIS/UUTTA/VALMIS/Maasto_5.txt", header=TRUE, sep="\t" )
```

#Mallien ajamiset stepclassilla

LDA:

```
Obj_2model <- stepclass(Obj_2 ~ ., data=Obj_2, method="lda", improvement=0.0001)
Obj_3model <- stepclass(Obj_3 ~ ., data=Obj_3, method="lda", improvement=0.0001)
Obj_4model <- stepclass(Obj_4 ~ ., data=Obj_4, method="lda", improvement=0.0001)

Maasto_2model <- stepclass(Maasto_2 ~ ., data=Maasto_2, method="lda", improvement=0.0001)
Maasto_3model <- stepclass(Maasto_3 ~ ., data=Maasto_3, method="lda", improvement=0.0001)
Maasto_5model <- stepclass(Maasto_5 ~ ., data=Maasto_5, method="lda", improvement=0.0001)
```

#QDA:

```
step2_obj <- stepclass(Obj_2 ~., data=Obj_2, method="qda", improvement=0.0001)
step3_obj <- stepclass(Obj_3 ~., data=Obj_3, method="qda", improvement=0.0001)
```

```
step4_obj <- stepclass(Obj_4 ~., data=Obj_4, method="qda", improvement=0.0001)
```

```
step2_maasto <- stepclass(Maasto_2 ~., data=Maasto_2, method="qda", improvement=0.0001)
```

```
step3_maasto <- stepclass(Maasto_3 ~., data=Maasto_3, method="qda", improvement=0.0001)
```

```
step5_maasto <- stepclass(Maasto_5 ~., data=Maasto_5, method="qda", improvement=0.0001)
```

#Mallien ajamiset stepAICilla

```
fit2_obj <- glm(Obj_2 ~ ., data=Obj_2)
```

```
fit3_obj <- glm(Obj_3 ~ ., data=Obj_3)
```

```
fit4_obj <- glm(Obj_4 ~ ., data=Obj_4)
```

```
fit2_maasto <- glm(Maasto_2 ~ ., data=Maasto_2)
```

```
fit3_maasto <- glm(Maasto_3 ~ ., data=Maasto_3)
```

```
fit5_maasto <- glm(Maasto_5 ~ ., data=Maasto_5)
```

```
step2_obj <- stepAIC(fit2_obj, steps=1000)
```

```
step3_obj <- stepAIC(fit3_obj)
```

```
step4_obj <- stepAIC(fit4_obj)
```

```
step2_maasto <- stepAIC(fit2_maasto)
```

```
step3_maasto <- stepAIC(fit3_maasto)
```

```
step5_maasto <- stepAIC(fit5_maasto)
```

MUUTTUJIEN VALINTA greedy.wilks toiminnon avulla

```
greedy.wilks (Obj_2~., CV=T, data=Obj_2)
```

```
greedy.wilks (Obj_3~., CV=T, data=Obj_3)
```

#Aineiston tarkatelu

```

fix(data)
str(data)
names(data)
summary(data)
summary(lda1)
var(data)
cor()

```

#Mallin tarkastelu ja kuvaajat

```

malli_lda_obj2 <- lda(Obj_2 ~ f_p5+f_p20+l_havg, data=Obj_2)
malli_lda_obj3 <- lda(Obj_3 ~ LNf_h20+ LNf_h40+ NELIO1_h5 , data=Obj_3) #!!!!
malli_lda_obj4 <- lda(Obj_4 ~ l_h5+ LNf_h20+ KAANf_h60, data=Obj_4) #!!!!
malli_lda_maasto_2 <- lda(Maasto_2 ~ KAANf_veg+KAANI_h20+KAANI_p80, data=Maasto_2)
malli_lda_maasto_3 <- lda(Maasto_3 ~ f_h20+ l_p95+ LNf_p20 , data=Maasto_3)
malli_lda_maasto_5 <- lda(Maasto_5 ~ l_p20+KAANI_p80+JUURIf_h40, data=Maasto_5)

```

```

malli_qda_obj2 <- qda(Obj_2 ~ f_h95+ f_p5+ NELIOf_p20, data=Obj_2)
malli_qda_obj3 <- qda(Obj_3 ~ LNI_havg+KAANf_h20+KAANf_h60, data=Obj_3)
malli_qda_obj4 <- qda(Obj_4 ~ LNf_h20+LNf_h40+NELIO1_h5, data=Obj_4)
malli_qda_maasto2 <- qda(Maasto_2 ~ NELIO1_veg+ NELIO1_p60+ KAANI_p60 , data=Maasto_2)
malli_qda_maasto3 <- qda(Maasto_3 ~ f_h40+ l_havg+ l_h40, data=Maasto_3)
malli_qda_maasto5 <- qda(Maasto_5 ~ l_p40+ LNf_h40+ NELIO1_p80, data=Maasto_5)

```

##ENNUSTEET

```

predict(malli_lda_obj2)$class
predict(malli_lda_obj3)$class
predict(malli_lda_obj4)$class
predict(malli_lda_maasto_2)$class
predict(malli_lda_maasto_3)$class
predict(malli_lda_maasto_5)$class

```

```

predict(malli_qda_obj2)$class
predict(malli_qda_obj3)$class
predict(malli_qda_obj4)$class
predict(malli_qda_maasto2)$class

```

```
predict(malli_qda_maasto3)$class
predict(malli_qda_maasto5)$class
```

##TAULUKOINTI

```
Taulu_lda_obj2 <- table(Obj_2$Obj_2, predict(malli_lda_obj2)$class)
Taulu_lda_obj3 <- table(Obj_3$Obj_3, predict(malli_lda_obj3)$class)
Taulu_lda_obj4 <- table(Obj_4$Obj_4, predict(malli_lda_obj4)$class)
Taulu_lda_maasto2 <- table(Maasto_2$Maasto_2, predict(malli_lda_maasto_2)$class)
Taulu_lda_maasto3 <- table(Maasto_3$Maasto_3, predict(malli_lda_maasto_3)$class)
Taulu_lda_maasto5 <- table(Maasto_6$Maasto_5, predict(malli_lda_maasto_5)$class)
```

```
Taulu_qda_obj2 <- table(Obj_2$Obj_2, predict(malli_qda_obj2)$class)
Taulu_qda_obj3 <- table(Obj_3$Obj_3, predict(malli_qda_obj3)$class)
Taulu_qda_obj4 <- table(Obj_4$Obj_4, predict(malli_qda_obj4)$class)
Taulu_qda_maasto2 <- table(Maasto_2$Maasto_2, predict(malli_qda_maasto_2)$class)
Taulu_qda_maasto3 <- table(Maasto_3$Maasto_3, predict(malli_qda_maasto_3)$class)
Taulu_qda_maasto5 <- table(Maasto_6$Maasto_5, predict(malli_qda_maasto_5)$class)
```

##OIKEINLUOKITUS (sisältää taulukot myös)

```
lo2 <-table(Obj_2$Obj_2, predict(malli_lda_obj2)$class)
lo2
acc_lda_obj2 <- (lo2[2,2]+lo2[1,1])/sum(lo2)*100
acc_lda_obj2
```

```
lo3 <-table(Obj_3$Obj_3, predict(malli_lda_obj3)$class)
lo3
acc_lda_obj3 <- (lo3[2,2]+lo3[1,1]+lo3[3,3])/sum(lo3)*100
acc_lda_obj3
```

```
lo4 <-table(Obj_4$Obj_34 predict(malli_lda_obj4)$class)
lo4
acc_lda_obj4 <- (lo4[2,2]+lo4[1,1]+lo4[3,3]+lo4[4,4])/sum(lo4)*100
acc_lda_obj4
```

```
lm2 <-table(Maasto_2$Maasto_2, predict(malli_lda_maasto_2)$class)
```

lm2

```
acc_lda_maasto2 <- (lm2[2,2]+lm2[1,1])/sum(lm2)*100
```

acc_lda_maasto2

```
lm3 <-table(Maasto_3$Maasto_3, predict(malli_lda_maasto_3)$class)
```

lm3

```
acc_lda_maasto3 <- (lm3[2,2]+lm3[1,1]+lm3[3,3])/sum(lm3)*100
```

acc_lda_maasto3

```
lm5 <-table(Maasto_5$Maasto_5, predict(malli_lda_maasto_5)$class)
```

lm5

```
acc_lda_maasto5 <- (lm5[2,2]+lm5[1,1]+lm5[3,3]+lm5[4,4]+lm5[5,5])/sum(lm5)*100
```

acc_lda_maasto5

```
qo2 <-table(Obj_2$Obj_2, predict(malli_qda_obj2)$class)
```

qo2

```
acc_qda_obj2 <- (qo2[2,2]+qo2[1,1])/sum(qo2)*100
```

acc_qda_obj2

```
qo3 <-table(Obj_3$Obj_3, predict(malli_qda_obj3)$class)
```

qo3

```
acc_qda_obj3 <- (qo3[2,2]+qo3[1,1]+qo3[3,3])/sum(qo3)*100
```

acc_qda_obj3

```
qo4 <-table(Obj_4$Obj_4, predict(malli_qda_obj4)$class)
```

qo4

```
acc_qda_obj4 <- (qo4[2,2]+qo4[1,1]+qo4[3,3]+qo4[4,4])/sum(qo4)*100
```

acc_qda_obj4

```
qm2 <-table(Maasto_2$Maasto_2, predict(malli_qda_maasto2)$class)
```

qm2

```
acc_qda_maasto2 <- (qm2[2,2]+qm2[1,1])/sum(qm2)*100
```

acc_qda_maasto2

```
qm3 <-table(Maasto_3$Maasto_3, predict(malli_qda_maasto3)$class)
```

qm3

```
acc_qda_maasto3 <- (qm3[2,2]+qm3[1,1]+qm3[3,3])/sum(qm3)*100
```

acc_qda_maasto3


```
qm5 <-table(Maasto_5$Maasto_5, predict(malli_qda_maasto5)$class)
qm5
acc_qda_maasto5 <- (qm5[2,2]+qm5[1,1]+qm5[3,3]+qm5[4,4]+qm5[5,5])/sum(qm5)*100
acc_qda_maasto5
```

Taulukko ominaisuuksia: nimeämiset

```
colnames(cm) <- c("aa", "bb")
cm
rownames(cm) <- c("aa", "bb")
cm
```