



■ Tero Heinonen



■ Vesa Leppänen



■ Timo Pukkala



■ Martin Gunia

Tero Heinonen, Vesa Leppänen, Timo Pukkala ja Martin Gunia

## Dynaamisiin käsittelykuvioihin perustuva metsäsuunnittelu

**Heinonen, T., Leppänen, V., Pukkala, T. & Gunia, M.** 2008. Dynaamisiin käsittelykuvioihin perustuva metsäsuunnittelu. *Metsätieteen aikakauskirja* 4/2008: 281–293.

Tutkimuksessa testattiin sellaista metsäsuunnittelman laadintatekniikkaa, jossa ei käytetä lainkaan perinteisiä metsikkökuvioita. Puustotunnukset tulkittiin kuusikulmion muotoisille pikseleille käyttäen laserkeilausaineistoa ja joukkoa suunnittelualueen läheltä mitattuja maastokoealoja. Lisäksi käytettiin digitaalista väri-infrakuvaa, jonka avulla pääteltiin, oliko tietty pikseli metsäpeitteetön, havupuustoinen vai lehtipuustoinen. Tutkimuksessa verrattiin kolmea pikselikokoa: 294 m<sup>2</sup>, 591 m<sup>2</sup> ja 1182 m<sup>2</sup>. Puustotunnusten tulkintamenetelmässä jokaiselle pikselille valittiin 50 ”lähintä” koealaa. Läheisyyttä mitattiin laser- ja väri-infra-aineistosta lasketuilla muuttujilla. Tulkintapikselille valittujen koealojen puustotunnusten ja laserpulsseista laskettujen muuttujien välille sovitettiin ennustin, jolla tulkintapikselin puustotunnukset saatiin laserpulsseja luonnehtivien muuttujien funktiona. Tulkintapikseleille simuloitiin vaihtoehtoisia käsittelyohjelmia kahdeksi 5-vuotiskaudeksi. Pikseleistä muodostettiin yhtenäisiä käsittely-yksiköitä spatiaalisen optimoinnin keinoin. Tulosten mukaan menetelmä on teknisesti toimiva, joskin osa käsittelykuvioista on varsin pieniä, ja käsittelykuvion sisälle voi jäädä käsittelemättömiä pikseleitä. Tämän tulkittiin olevan seurausta metsäalueen puuston heterogeenisuudesta eikä niinkään menetelmän kyvyttömyydestä ryhmittää metsän piirteitä ja käsittelyjä spatiaalisesti. Suurin pikselikoko tuotti vähiten sirpaleisen hakkuuehdotuksen, mutta pienin pikselikoko taas tuotti suurimman nettotulojen nykyarvon, kun hakkuukertymä vakioitiin.

Asiasanat: laserkeilaus, lidar, kaukokartoitus, spatiaalinen optimointi, aligradianttimenetelmä  
Yhteystiedot: Joensuun yliopisto, PL 101, 80101 Joensuu  
Sähköposti [tero.heinonen@joensuu.fi](mailto:tero.heinonen@joensuu.fi)  
Hyväksytty 21.10.2008

## I Johdanto

Metsän inventoinnin menetelmävalikoima on viime vuosina laajentunut nopeaan tahtiin. Esimerkkejä uusista mahdollisuuksista ovat erotuskyvyltään tarkan satelliittiaineiston käyttö, numeerisen ilmakuvan segmentointimenetelmät sekä laserkuvaus. Tyypillistä monille uusille menetelmille on, että ne tuottavat pienipiirteistä paikkaan sidottua tietoa; inventointituloksia voidaan laskea perinteistä metsikkökuvioita huomattavasti pienemmille yksiköille. Inventoinnin kannalta kiinteärajaisten ja suurten kuvioiden ongelma on niiden sisäinen heterogeenisuus; kuviotieto on keskiarvotietoa, josta ei päästä käiksi kuvion sisäiseen hajontaan.

Viime aikoina runsaasti huomiota saanut inventoinnin suuntaus on laserkeilaus. Laser tuottaa lähinnä tietoa siitä, missä maan pinta ja latvuston pinta sijaitsevat. Latvuston ja maan pinnan erotuksena saadaan tietoa puuston pituudesta metsikön ja metsän eri kohdissa. Puukohtaisessa laseraineiston tulkinnassa tunnistetaan puiden latvuksia, jolloin latvusten läpimitan ja puiden pituuden perusteella saadaan tietoa yksittäisistä puista (esim. Hyypä ja Inkinen 1999, Maltamo ym. 2004). Toinen tulkintalinja, jota myös tässä tutkimuksessa käytetään, on piirre pohjainen. Siinä analysoidaan pienalueen laserpulsseja kokonaisuutena. Laserpulsseista, esim. niiden vertikaalijakaumasta, voidaan laskea muuttujia, joista metsikkötunnukset voidaan ennustaa regressiomalleilla. Jos käytettävissä on maastokoealoja, voidaan käyttää myös lähimmän naapurin tekniikkaa: tulkittavalle osa-alueelle, esim. pikselille, etsitään sellaisia maastokoealoja, jotka tuottavat samanlaisen pulssikokonaisuuden kuin tulkittava pikseli. Tulkittavan pikselin puustotunnuksina käytetään näin löydettyjen maastokoealojen mitattuja tunnuksia.

Myös metsäsuunnitelman koostamismenetelmät ovat kehittyneet nopeasti. Spatiaalisen optimoinnin avulla pieniä tulkintayksiköitä voidaan yhdistellä toteutuskelpoisiksi käsittely-yksiköiksi. Pienipiirteinen inventointi yhdessä spatiaalisen optimoinnin kanssa mahdollistaa suunnittelun, jossa ei käytetä lainkaan perinteisiä kiinteitä metsikkökuvioita (ks. Tuominen ym. 2006). Kuviot syntyvät optimointilaskelmien tuloksena ja ovat luonteeltaan dynaami-

sia eli tilapäisiä; tiettyä kuviota ei enää tarvita sen jälkeen, kun se toimenpideketju, jota varten kuvio muodostettiin, on toteutettu. GPS-tekniikan ansiosta myöskään puunkorjuu ei edellytä kiinteitä ja pysyviä kuvionrajoja. Optimoinnin tuloksena syntynyt käsittelykuviointia voidaan siirtää hakkuukoneen tietokoneeseen, jolloin koneen ohjaaja näkee tietokoneen näytöltä, missä käsittelykuvio on, ja milloin kone on kuvion sisällä.


Kiinteärajaisten kuvioista luopuminen tehostaa metsävarojen käyttöä (Heinonen ym. 2007), koska vaihtoehtojen määrä tiettyä pinta-alaa kohden suurenee. Suunnittelun kannalta kuvionrajat ovat rajoitteita, jotka kaventavat suunnittelun mahdollisuuksia.

Viime aikoina on tutkittu mm. laser-inventoinnin tarkkuutta ja kustannuksia (Næsset 2002, Næsset 2004, Suvanto ym. 2005). Toisaalta on kehitetty ja tutkittu spatiaalista optimointia (Bettinger ym. 1997, Hoganson ja Borges 1998, Baskent ja Jordan 2002, Kurttila ym. 2002, Heinonen ja Pukkala 2004, 2007, Pukkala ja Heinonen 2006) ja selvitetty spatiaalisen optimoinnin kykyä ryhmittää pikseleitä käsittely-yksiköiksi (Holmgren ja Thuresson 1997, Lu ja Eriksson 2000, Heinonen ym. 2007). Sitä laskennallisten vaiheiden ketjua, jonka käyttöä kuvioista vapaa metsäsuunnittelu edellyttää, ei kuitenkaan ole tutkittu kokonaisuutena. Tässä tutkimuksessa selvitetään sitä, millaisia tuloksia niillä menetelmillä saadaan, jotka nykyisin ovat käytettävissä, kun halutaan kiinteistä kuvioista vapaata metsäsuunnittelua. Toisena tavoitteena on analysoida, millaisia vaikutuksia tulkintayksikön koolla on suunnittelulaskelmiin.


## 2 Aineisto ja puustotunnusten tulkinta

### 2.1 Suunnittelualue

Suunnittelualue oli Pohjois Karjalassa, Juuassa sijaitseva Metsähallituksen omistama tila. Tilan kokonaispinta-ala on 440 ha, josta metsämaata on 376,8 ha. Loppuosa on pääosin avosoita. Tilan kokonaistilavuudesta kuusta ja mäntyä on suunnilleen saman verran. Muita puulajeja, pääosin koivua, on vähän (taulukko 1). Tilan puusto on nuorta (kuvat 1



Kuva 1. Suunnittelalueen puuston ikäluokkajakauma.






Kuva 2. Tulkintasolujen puuston ikäluokka pikselikoolla 294 m<sup>2</sup>.


Taulukko 1. Suunnittelalueen puuston keskitilavuus metsämaalla puu- ja puutavaralajeittain (m<sup>3</sup>/ha).

Puulaji	Tukki	Kuitu	Energiaranka	Yhteensä
Mänty	10	30	6	46
Kuusi	23	26	3	52
Muut puulajit	1	15	6	22
Yhteensä	34	71	15	120

ja 2), joten välittömät uudistushakkuumahdollisuudet ovat melko vähäiset. Metsä on heterogeenista, ja selkeärajaisia kuvioita on vähän (kuvat 2 ja 3).



Kuva 3. Tulkintasolujen puuston keskiläpimittaluokka pikselikoolla 294 m<sup>2</sup> (ylhällä), 591 m<sup>2</sup> (keskellä) ja 1182 m<sup>2</sup> (alhaalla).



**Kuva 4.** LiDAR-pisteparven sivuleikkauskuvaa (A). Kuvassa näkyvän leikkauksen pituus on 170 metriä. Leikkauskohta on esitetty osakuvassa B. Pisimpien kuvassa näkyvien puiden pituus on 19 metriä. Kuvan alareunassa näkyvät pisteet on luokiteltu maasta tulleiksi kaiuiksi ja muut pisteet kasvillisuudesta heijastuneiksi.

## 2.2 Puustotunnusten tulkintasolukko


Puustotunnukset tulkittiin kuusikulmion eli heksagonin muotoisille rasterisoluille. Heksagoni on tehokkain solun muoto naapuruustarkastelussa, koska solun yhteinen rajaviiva kaikkien naapureiden kanssa on yhtä pitkä. Näinollen optimoinnissa ei tarvitse käsitellä kahdenlaisia naapureita (vierekkäiset ja nurkittaiset), kuten neliön muotoisilla soluilla joudutaan tekemään. Jokaiselle solukon solulle eli pikselille ennustettiin puustotunnukset itsenäisesti. Käytetyt solukoot olivat: 294 m<sup>2</sup>, 591 m<sup>2</sup> ja 1182 m<sup>2</sup>. Solukoko 294 m<sup>2</sup> on lähes sama kuin käytetyn maastokoealan pinta-ala (254 m<sup>2</sup>). Keskimäinen solukoko oli noin kaksi kertaa pienin koko, ja suurin koko saatiin kertomalla keskimäinen koko kahdella.

## 2.3 LiDAR-aineisto

Tulkinnassa käytettiin LiDAR-aineistoa, numeerista väri-infrakuva ja ympyrän muotoisia maastokoealoja. LiDAR on lyhenne sanoista light detection and ranging (sensor). LiDAR-aineiston keskimääräinen pistetiheys oli 0,7 pulssia/m<sup>2</sup>. Pulssitiheys vaihteli välillä 0,5–1 pulssia / m<sup>2</sup>. Kuvauskulman poikkeama pystysuunnasta oli 0–17 astetta.

## 2.4 Väri-infra-aineisto

Tutkimuksessa käytettiin LiDAR-aineiston ohella myös Vexcel UltraCamD -digitaalisen sensorilla otettua kolmikanavaista väri-infrakuva. Kuvan erotuskyky oli 0,25 m, ts. pikselikoko oli 0,25 m x 0,25 m. Sävyarvojen erottelutarkkuus oli 8 bittiä/kanava (sävyarvon vaihteluväli oli siis 0–255). Kuva oli valmiiksi sävyarvotasoitettu.



**Kuva 5.** Maastokoealojen paikat. Suunnittelualue on rajattu harmaalla paksulla viivalla.

Väri-infra-aineiston käsittelyssä käytettiin robustia ja helposti säädettävää pikselitason luokitinta, joka antaa käyttökelpoisen luokitustuloksen, kun kuva-aineiston sävyarvot on hyvin tasoitettu koko suunnittelualueelle. Mikäli sävyarvotasoitus ei ole onnistunut tai se on tehty erikseen alueen eri osille, luokitin on säädettävä erikseen eri kuva-alueille. Sääto on tehtävä siten, että havu- ja lehtipuupikselien määrä vastavan tyyppisillä metsiköillä on sama eri kuva-alueilla.

Väri-infrakuvan pikselit luokiteltiin ensin kahteen luokkaan: puustoon osuneet pikselit ja muihin kohteisiin osuneet pikselit. Puustoksi tulkittiin pikselit, joissa vihreän kanavan sävyarvo (asteikolla 0–255) oli yli 10 yksikköä suurempi kuin punaisen kanavan sävyarvo. Puustoon osuneet pikselit luokiteltiin edelleen kahteen luokkaan: lehtipuustoon osuneet pikselit ja muuhun kuin lehtipuustoon osuneet pikselit. Lehtipuustoon osuneiksi tulkittiin ne puustoiset pikselit, joiden infrapunaisen kanavan sävyarvon ja punaisen kanavan sävyarvon ero oli suurempi kuin 50. Lehtipuustoon osuneiden pikselien joukkoa kutsutaan jäljempänä 'lehtipu-

maskiksi' ja havupuustoon osuneiden pikselien joukkoa 'havupuumaskiksi'.

## 2.5 Maastokoealat

Maastokoealat, joita oli 477 kpl, mitattiin suunnittelualueen ympäristöstä (kuva 5). Sekä LiDAR- että ilmakuva-aineisto kattoi kaikki koealat. Maastossa käytettiin kiinteäsäteisiä ympyräkoealoja, joiden säde oli 9 m. Koealan keskipisteen koordinaatit määritettiin GPS-laitteella, ja paikannustarkkuutta parannettiin differentiaalikorjauksella. Kaikista rinnakorkeuslähimitaltaan yli 5 cm paksuista puista määritettiin puulajiluokka (mänty, kuusi, lehtipuu) ja mitattiin rinnankorkeuslähimitta. Pituuskoepuista mitattiin lisäksi puun pituus. Koealojen pituuskoepuiden lähimittan ja pituuden välille sovitettiin regressiomalli. Niille koealojen puille, joilta pituusmittaus puuttui, se laskettiin pituusmallilla.

Mitattujen tunnusten avulla koealoille laskettiin puulajiluokittain pohjapinta-ala, pohjapinta-alalla painotettu keskipituus, kokonaistilavuus, pohjapinta-alalla painotettu keskilähimitta ja runkoluku. Koealatunnusten keskiarvot, minimi- ja maksimi-arvot sekä vaihteluvälit ovat taulukossa 2.

## 2.6 Puustotunnusten ennustaminen soluille

Puustotunnukset ennustettiin rasterisolulle käyttäen ns. harvaa bayesiläistä regressiota (Tipping 2001) ja koealavalintaa (Junttila ym. 2008, käsikirjoitus). Jokaiselle solulle valittiin koeala-aineistosta 50 lähintä naapurua (most similar neighbor). Läheisyyttä mitattiin seuraavilla laser- ja väri-infra-aineistosta lasketuilla muuttujilla, jotka oli skaalattu vaihteluväliin 0–100:

- Laserpulssien vertikaalijakauman 85 % prosenttiosuuden korkeus
- Havupuumaskin havupuupikselien lukumäärä
- Lehtipuumaskin lehtipuupikselien lukumäärä

Nämä muuttujat valittiin subjektiivisesti tarkoitukseksi käyttää puuston pituutta ja puulajisuhteita kuvaavia muuttujia.

Jokaiselle tulkintayksikölle muodostettiin erillinen puustotunnusten ennustemalli käyttäen aineistona

**Taulukko 2.** Koealojen puustotunnusten keskiarvo, hajonta ja vaihteluväli.

Tunnus	Keskiarvo	Minimi-arvo	Maksimi-arvo	Keski-hajonta
Kaikkien puulajien yhteinen pohjapinta-alalla painotettu keskiläpimitta, cm	19,2	7,6	49,4	5,8
Kaikkien puulajien yhteinen pohjapinta-alalla painotettu keskipituus, m	14,7	6,0	25,2	3,6
Kaikkien puulajien yhteinen runkoluku	1289,9	158,0	4127,0	594,7
Kaikkien puulajien yhteinen pohjapinta-ala, m <sup>2</sup> /ha	20,3	1,5	55,0	8,7
Kaikkien puulajien yhteinen tilavuus, m <sup>3</sup> /ha	145,2	5,5	484,9	80,9
Pohjapinta-alalla painotettu keskiläpimitta, mänty	17,6	0,0	54,3	8,1
Pohjapinta-alalla painotettu keskipituus, mänty	13,2	0,0	25,0	5,5
Männyn runkoluku	586,8	0,0	2122,0	446,0
Männyn pohjapinta-ala	11,9	0,0	37,7	8,2
Männyn tilavuus	87,6	0,0	351,0	68,6
Pohjapinta-alalla painotettu keskiläpimitta, kuusi	10,4	0,0	44,2	8,4
Pohjapinta-alalla painotettu keskipituus, kuusi	8,3	0,0	25,3	6,4
Kuusen runkoluku	407,4	0,0	2319,0	495,8
Kuusen pohjapinta-ala	5,8	0,0	45,0	8,8
Kuusen tilavuus	41,6	0,0	448,8	72,8
Pohjapinta-alalla painotettu keskiläpimitta, lehtipuu	8,9	0,0	44,5	6,7
Pohjapinta-alalla painotettu keskipituus, lehtipuu	8,8	0,0	27,7	5,9
Lehtipuun runkoluku	295,7	0,0	3183,0	450,3
Lehtipuun pohjapinta-ala	2,6	0,0	30,1	4,4
Lehtipuun tilavuus	16,0	0,0	230,3	29,2

**Taulukko 3.** Puustotunnusten ennustemallin selittäjät.

Muuttuja	Kuvaus
$x_{1..x_{10}}$	Ensimmäisten kaikujen 20%, 30% ... 100% prosenttiosuukien korkeus maanpinnasta. Prosenttiosuuden korkeus on korkeus, jonka alapuolelle jää ko. osuuden verran estimointiyksikön alueella olevien pisteiden kokonaismäärästä.
$x_{11..x_{18}}$	Sellaisten viimeisten kaikujen prosenttiosuus kaikista viimeisistä kauista, joiden korkeus on alle $3i + 0,5$ , $i = 0..7$ .
$x_{19..x_{21}}$	Sellaisten ensimmäisten kaikujen prosenttiosuus kaikista ensimmäisistä kauista, joiden intensiteetti on $I \leq 0,5+i$ , $i \in \{0, 1, 2\}$
$x_{22..x_{24}}$	Sellaisten viimeisten kaikujen prosenttiosuus kaikista viimeisistä kauista, joiden intensiteetti on $I \leq 0,5+i$ , $i \in \{0, 1, 2\}$
$x_{25}$	Yli 5 m korkeudelta maan pinnasta tulleiden ensimmäisten kaikujen keskikorkeus maan pinnasta.
$x_{26}$	Logaritmi sellaisten ensimmäisten kaikujen prosenttiosuudesta kaikista kauista, joiden korkeus maanpinnasta on alle 2 m.
$x_{27}$	Kolmen korkeimman kasvillisuuspisteen keskikorkeus.

tulkintayksikölle valittuja 50 lähintä koealapikseliä ja ko. pikseleiden koealojen puustotunnuksia. Selittävinä muuttujina käytettiin taulukossa 3 lueteltuja kasvillisuuden korkeusmallista laskettuja tunnuksia, jotka on mukailtu Naesetin (2002) tutkimuksesta. Bayesiläinen ennustemenetelmä valitsee selittävien muuttujien joukosta ne, joiden kovarianssi ennustettavan selitettävän muuttujan kanssa on suurin. Solukohtaiseen malliin tuli mukaan tavallisesti 5–7 selittävää muuttujaa. Tulkintayksikön puustotunnuk-

set laskettiin mallilla sijoittamalla siihen kyseisen estimointiyksikön selittävien muuttujien arvot.

Bayesiläinen menetelmä ennustaa kaikki selittävät muuttujat toisistaan riippumatta. Puustotunnukset ovat kuitenkin todellisuudessa toisistaan riippuvaisia. Jotta tunnukset olisivat keskenään johdonmukaisia, tehtiin niille ns. konsistenssikorjaus. Konsistenssi-korjauksessa minimoidaan yksittäisten tunnusten korjausta:

$$\min z = \sum_{i=1}^I \frac{(f_i - f'_i)^2}{\sigma_i^2}$$

missä  $I$  = estimoitavien tunnusten lukumäärä,  $f_i$  = tunnuksen  $i$  korjaamaton ennuste,  $f'_i$  = tunnuksen  $i$  korjattu arvo, ja  $\sigma_i^2$  = tunnuksen  $i$  otosvarianssi koeala-aineistosta laskettuna. Mitä pienempi on tunnuksen otosvarianssi, sitä vähemmän kyseinen tunnus muuttuu korjauksessa. Minimointi tehtiin seuraavin rajoittein:

$$V = V_{Ku} + V_{Le} + V_{Ma}$$

$$G = G_{Ku} + G_{Le} + G_{Ma}$$

$$N = N_{Ku} + N_{Le} + N_{Ma}$$

$$\frac{H}{G} = \frac{(H_{Ku} + H_{Le} + H_{Ma})}{(G_{Ku} + G_{Le} + G_{Ma})}$$

$$V_{Ku} + G_{Ku}(2,3 + (H_{Ku} - 3) \times 0,43) \quad (\text{Kuusen tilavuus})$$

$$V_{Ma} = -1,75e^{-13} + 1,3G_{Ma} +$$

$$5,3e^{-15}H_{Ma} + 0,4G_{Ma}H_{Ma} \quad (\text{Männyn tilavuus})$$

$$V_{Le} = G_{Ku}(2 + (H_{Ku} - 3) \times 0,41) \quad (\text{Koivun tilavuus})$$

missä  $V$  = puuston kokonaistilavuus estimointiyksiköllä,  $V_{Ku}$  = kuusen kokonaistilavuus,  $V_{Le}$  = lehtipuun kokonaistilavuus,  $V_{Ma}$  = männyn kokonaistilavuus,  $G$  = puuston pohjapinta-ala,  $G_{Ku}$  = kuusen pohjapinta-ala,  $G_{Le}$  = lehtipuun pohjapinta-ala,  $G_{Ma}$  = männyn pohjapinta-ala,  $N$  = puuston runkoluku,  $N_{Ku}$  = kuusen runkoluku,  $N_{Le}$  = lehtipuun runkoluku,  $N_{Ma}$  = männyn runkoluku,  $H$  = puuston pohjapinta-alalla painotettu pituus,  $H_{Ku}$  = kuusen pohjapinta-alalla painotettu pituus,  $H_{Le}$  = lehtipuun pohjapinta-alalla painotettu pituus ja  $H_{Ma}$  = männyn pohjapinta-alalla painotettu pituus.

Minimoinnissa käytettiin Opt++ -optimointikirjastoja epälineaarille yleisesti rajoitetuille ongelmille. Optimoija on muunnos epälineaarisesta sisäpistehausta, jossa approksimoidaan gradienttimatriisia ja hessin matriisia äärellisillä differensseillä (Meza ym. 2007). Puustotunnusten ennustuksen luotettavuutta mitattiin laskemalla koealoille RMSE-arvot (taulukko 4). Tulosten mukaan kokonaispuustolle lasketut ennusteet ovat varsin luotettavia, mutta puulajeittaisissa tunnuksissa virhevaihtelu on suurta. Ennusteiden keskivirhe on jonkin verran pienempi kuin Packalénin ja Maltamon (2007) tutkimuksessa.

**Taulukko 4.** Puustotunnusten ennusteiden suhteelliset keskivirheet tutkimuksessa käytetyssä tulkintamenetelmässä.

Tunnus	RMSE, %
Pohjapinta-alalla painotettu keskiläpimitta	13,6
Pohjapinta-alalla painotettu keskipituus	8,0
Runkoluku	22,5
Pohjapinta-ala	13,3
Tilavuus	14,3
Pohjapinta-alalla painotettu keskiläpimitta, kuusi	22,7
Pohjapinta-alalla painotettu keskiläpimitta, lehtipuu	36,7
Pohjapinta-alalla painotettu keskiläpimitta, mänty	29,1
Pohjapinta-alalla painotettu keskipituus, kuusi	22,9
Pohjapinta-alalla painotettu keskipituus, lehtipuu	32,8
Pohjapinta-alalla painotettu keskipituus, mänty	24,5
Runkoluku, kuusi	54,3
Runkoluku, lehtipuu	64,3
Runkoluku, mänty	37,9
Pohjapinta-ala, kuusi	56,4
Pohjapinta-ala, lehtipuu	69,6
Pohjapinta-ala, mänty	30,2
Tilavuus, kuusi	58,7
Tilavuus, lehtipuu	76,0
Tilavuus, mänty	30,4

### 3 Suunnitelmien koostaminen

Pikseille simuloitiin käsittelyvaihtoehtoja kahdeksi 5-vuotiskaudeksi Monsu-ohjelmiston metsikkösimulaattorilla (Pukkala 2004). Simulaattori noudattaa metsänkäsittelyohjeita siten, että uudistushakkuu simuloidaan aikaisintaan silloin, kun uudistamiseen vaadittava minimi-ikä tai minimikeskiläpimitta ylittyy. Uudistushakkuuta seuraavat toimet, kuten maanpinnan käsittely, istutus ja taimikon hoito, simuloidaan aina. Harvennushakkuu simuloidaan aikaisintaan silloin, kun ns. ”leimausraja” eli valtapituudesta, puulajista ja kasvupaikasta riippuva minimipohjapinta-ala ylittyy. Tämän lisäksi Monsu tuottaa vaihtoehtoja, joissa hakkuu tapahtuu myöhemmin kuin se voisi ohjeen mukaan tapahtua. Jokaiselle kuviolle tai pikselille simuloidaan myös vaihtoehto, jossa ei ole lainkaan kaupallisia hakkuita. Kun suunnittelu kattaa kaksi 5-vuotiskautta, kuviolle tai pikselille tulee yleensä alle viisi käsittelyvaihtoehtoa.

Simuloinnissa käsittelyvaihtoehdoille lasketaan puustotunnusten kehitys, hakkuukertymä puutavaralajeittain, muiden toimenpiteiden kuin hakkuun kustannukset, hakkuutulot sekä nettotulojen nykyarvo eri korkokannoilla. Hakkuutulot lasketaan kantohinnoin, jolloin korjuukustannukset tulevat otetuiksi huomioon keskimääräisinä. Nykyarvo lasketaan diskonttaamalla suunnittelukauden nettotulot ensimmäisen vuoden alkuun. Tähän lisätään loppupuuston tuottoarvon nykyarvo, joka kuvaa suunnittelukauden jälkeen saatavien nettotulojen nykyarvoa. Loppupuuston tuottoarvo lasketaan Pukkalan (2006) malleilla.

Optimoinnissa käytettiin soluautomaattiin (cellular automaton) perustuvaa heuristista menetelmää. Soluautomaattien on havaittu olevan nopeita ja tehokkaita silloin, kun laskentayksiköitä on paljon (Strange ym. 2002, Heinonen ja Pukkala 2007). Soluautomaatit ryhmittävät tehokkaasti haluttuja metsän piirteitä (esim. habitaatteja, käsittelyjä). Silloin, kun soluautomaattia käytetään optimointiin, paras käsittely valitaan periaatteessa jokaiselle kuviolle tai pikselille erikseen, mutta parhaan käsittelyn valinnassa otetaan huomioon myös naapurikuvioiden tai -pikselien ominaisuuksia. Jos suunnittelussa on lisäksi koko metsäaluetta koskevia tavoitteita ja rajoitteita, myös ne on otettava huomioon laskentayksiköiden käsittelyä valittaessa.

Tässä tutkimuksessa maksimoitiin 2 %:n korkokannalla laskettua pikselin nykyarvoa. Tavoitefunktion liitettiin lisäksi tunnuksia, jotka kuvaavat pikselin käsittelyä suhteessa naapuripikselihin. Näiden tunnusten tavoitteena oli ryhmittää käsittelyitä spatioalisesti. Naapuristotunnukset olivat:

- Hakkuu–hakkuurajan osuus pikselin rajasta (HH). Tunnus saa arvon yksi, jos sekä pikseli että kaikki sen kuusi naapuripikseliä hakataan samalla suunnittelukaudella. Tunnus saa arvon nolla silloin, kun joko pikseliä tai yhtään sen naapurua ei hakata. Tätä tunnusta maksimoitiin tavoitteena keskittää hakkuuta.
- Hakkuu–ei–hakkuurajan osuus pikselin rajasta (HEH). Tunnus saa arvon yksi mm. silloin, kun pikseli hakataan mutta yhtään sen naapurua ei hakata samalla kaudella. Tätä tunnusta minimoitiin tavoitteena välttää yksittäisiä hakattuja pikseleitä.
- Uudistushakkuu–ei–uudistushakkuurajan osuus pikselin rajasta (UHEUH). Tunnus saa arvon yksi mm. silloin, kun pikseli uudistetaan mutta yhtään

sen naapurua ei uudisteta samalla kaudella. Tätä tunnusta minimoitiin tavoitteena välttää yksittäisiä uudistushakattuja pikseleitä.

Funktio, jota maksimoitiin pikselitasolla, oli

$$OF_{\text{solu}} = a_1(\text{NPV}/\text{NPV}_{\text{max}}) + a_2\text{HH} - a_3\text{HEH} - a_4\text{UHEUH} \quad (1)$$

Käsittelyohjelman tuottama hehtaarikohtainen nykyarvo (NPV) jaettiin suurimmalla nykyarvolla, joka kaikkien pikselien käsittelyvaihtoehtojen joukosta löytyi. Tämän muunnoksen seurauksena kaikki tavoitemuuttujat olivat suhdelukuja, jolloin tavoitepainot ( $a_1, \dots, a_4$ ) voidaan asettaa ajattelematta tavoitemuuttujien yksiköitä. Jos tavoitepainojen summa on yksi, kuten tässä tutkimuksessa, myös tavoitefunktion arvo on suhdeluku, joka kuvaa käsittelyvaihtoehdon arvoa suhteessa tilanteeseen, jossa kaikki tavoitemuuttujat saavat parhaan mahdollisen arvon. Tavoitepainot olivat joka pikselikoolla samat:  $a_1 = 0,05$ ,  $a_2 = 0,15$ ,  $a_3 = 0,60$ ,  $a_4 = 0,20$ . Kertoimet osittavat, että optimoinnissa pantiin paljon painoa yksittäisten hakattujen pikselien välttämiseksi. Näin jouduttiin tekemään toisaalta siksi, että ratkaisu oli varsin epäherkkä tavoitepainoille, ja toisaalta siksi, että suunnittelualue oli puustoltaan heterogeenista, minkä vuoksi metsässä oli runsaasti sellaisia pikseleitä, joissa harvennus- tai uudistushakkuun kriteerit täytyivät mutta joiden naapureissa kriteerit eivät täytyneet.

Jos suunnittelussa on koko alueeseen liittyviä tavoitteita tai rajoitteita, yhtälön 1 maksimointi jokaisessa pikselissä erikseen ei yleensä johda niiden toteutumiseen. Tässä tutkimuksessa oli kolme koko alueeseen liittyvää rajoitetta:

- Ensimmäisen 5-vuotiskauden hakkuukertymän ( $H_1$ ) tuli olla vähintään 15000 m<sup>3</sup>
- Toisen 5-vuotiskauden hakkuukertymän ( $H_2$ ) tuli olla vähintään 20000 m<sup>3</sup>
- Puuston tilavuuden (V) tuli 10 vuoden päästä olla vähintään 50000 m<sup>3</sup>

Aluekohtaiset tavoitteet otettiin huomioon Hogansoin ja Rosen (1984) esittämällä menetelmällä, jossa kuvio- tai pikselitason optimointitehtävät sidotaan toisiinsa redusoitujen kustannusten avulla. Tämän tutkimuksen tavoitteisiin ja rajoitteisiin sovellettu



redusoitujen kustannusten laskentakaava oli

$$RC = OF_{\text{solu}} - v_1 H_1 - v_2 H_2 - v_3 V \quad (2)$$

missä  $v_1$ ,  $v_2$  ja  $v_3$  ovat aluetason rajoitteiden varjohinnat ja  $OF_{\text{solu}}$  on yhtälöllä 1 laskettu tavoitefunktion arvo. Varjohinnat olivat aluksi nollia. Valituista käsittelyvaihtoehdoista laskettiin rajoitemuuttujien  $H_1$ ,  $H_2$  ja  $V$  arvo koko alueella. Niiden perusteella varjohinnoille laskettiin uudet arvot ( $v_{k,t+1}$ ) aligradien menetelmässä (engl. *sub-gradient method*) käytetyllä tekniikalla (Beasley 1993):

$$v_{k,t+1} = v_{k,t} + \text{Askel}_k \text{Kerroin}_{k,t}$$

missä

$$\text{Kerroin}_{k,t} = \begin{cases} 0 & \text{jos } q_{k,t} = T_k \\ (q_{k,t} - T_k) / |q_{k,t} - T_k| & \text{jos } q_{k,t} \neq T_k \end{cases}$$

Päivitetyt varjohinnat on oltava vähintään nolla ”pienempi tai yhtäsuuri kuin” -tyypin rajoitteille ja enintään nolla ”suurempi tai yhtäsuuri kuin” -tyypin rajoitteille (kuten kaikki tämän tutkimuksen rajoitteet). Symboli  $q_k$  tarkoittaa valittujen käsittelyvaihtoehtojen tuottamaa rajoitemuuttujan  $k$  arvoa ( $H_1$ ,  $H_2$  tai  $V$ ) ja symboli  $T_k$  rajoitemuuttujan  $k$  tavoitearvoa. Parametri  $\text{Askel}_k$  ilmoittaa varjohinnat  $k$  muutospöuden.

Muutosaskeleen alkuarvo oli kaikille rajoitteille 0,0001. Askelpituudet puolitettiin, jos aluetason tavoitefunktio ei parantunut kuuteen kierrokseen ( $2 \times$  rajoitteen lukumäärä = 6). Kierros tarkoittaa sitä, että jokaiselle solulle valitaan kerran paras käsittelyvaihtoehto. Aluetason tavoitefunktio, jota minimoidaan, on seuraava:

$$OF_{\text{alue}} = \sum_{j=1}^n RC_j + \sum_{k=1}^m v_k T_k$$

missä  $RC_j$  on pikselin  $j$  redusoitu kustannus,  $n$  pikselien lukumäärä,  $m$  rajoitteiden lukumäärä,  $v_k$  rajoitteen  $k$  varjohinta ja  $T_k$  rajoitteen  $k$  tavoitearvo.

Varjohintojen päivityksen jälkeen pikseleille valittiin uudelleen paras käsittelyohjelma maksimoimalla redusoitujen kustannusten kaavaa. Näin jatkettiin, kunnes kaikki rajoitteet täyttyivät vähintään 99-prosenttisesti. Tuloksena oli sellainen käsittelyvaihto-

**Taulukko 5.** Tavoite ja rajoitemuuttujien arvot eri pikselikoolla tuotetuissa suunnitelmissa. Rajaosuudet (HH, HEH, UHEUH) tarkoittavat rajaosuutta koko alueella kahdella 5-vuotiskaudella keskimäärin. 'Max' tarkoittaa, että tunnusta maksimoitiin ja 'min', että tunnusta minimoitiin.

Tavoite tai rajoite	Pikselin koko, m <sup>2</sup>		
	294	591	1182
NPV, € (max)	2718850	2673918	2552465
HH (max)	0,298	0,281	0,268
HEH (min)	0,161	0,144	0,173
UHEUH (min)	0,087	0,073	0,101
H <sub>1</sub> , m <sup>3</sup> (tavoite 15000 m <sup>3</sup> )	14995	15095	14703
H <sub>2</sub> , m <sup>3</sup> (tavoite 20000 m <sup>3</sup> )	23706	21163	19331
V, m <sup>3</sup> (tavoite 50000 m <sup>3</sup> )	50004	50278	49984

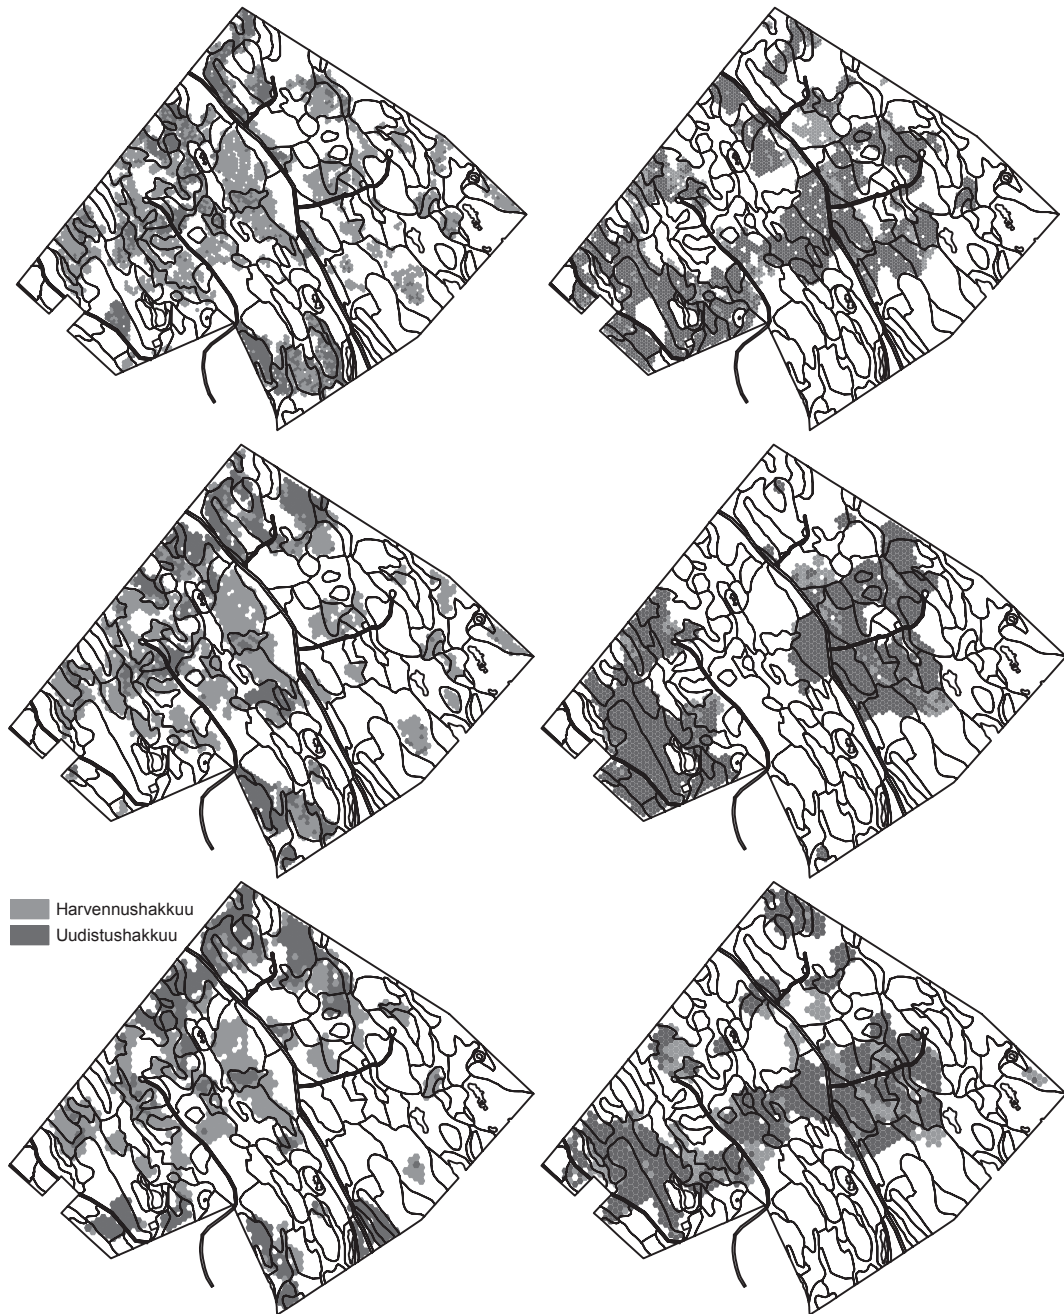
ehtojen yhdistelmä, joka toisaalta maksimoi pikselitason tavoiteyhtälöä mutta toisaalta täytti aluetason rajoitteet.

## 4 Tulokset

Rajoitemuuttujien arvot saavutettiin optimisuunnitelmissa joka pikselikoolla vähintään 99-prosenttisesti (taulukko 5). Pienellä pikselikoolla (294 ja 591 m<sup>2</sup>) toisen kauden hakkuurajoite (20000 m<sup>3</sup>) jopa ylittyi selvästi. Nettotulon nykyarvo oli suurin pikselikoolla 294 m<sup>2</sup>, samoin hakkuu-hakkuurajan osuus kaikista pikselien välisestä rajasta. Hakkuu-ei-hakkuurajan osuus ei riippunut systemaattisesti pikselikoosta. Tavoite- ja rajoitemuuttujien arvojen perusteella on siis pääteltävissä, että pienin pikselikoko tuotti parhaan ja suurin koko heikoimman suunnitelman.

Hakkuiden sijoittumista kuvaavista kartoista on nähtävissä, että hakkuiden ajoitus ja sijoittuminen riippuvat pikselikoosta (kuva 6). Jokaisella pikselikoolla on ensimmäisellä 5-vuotiskaudella uudistettu ne vähäiset muutamaa solua suuremmat alueet, jotka iän (kuva 2) ja puuston läpimitan (kuva 3) perusteella täyttävät uudistuskypsyyden kriteerit. Ensimmäisen 5-vuotiskauden harvennushakkuut ovat sijoittuneet samantapaisesti pikselikoosta riippumatta.

Toisella kaudella, jolloin uudistushakkuumahdollisuuksia on jo enemmän, uudistushakkuut ovat ryhmittyneet huomattavasti paremmin kuin ensimmä-



**Kuva 6.** Pikselit, joille käsittelyksi on valittu harvennushakkuu (vaaleanharmaa) tai uudistushakkuu (tummanharmaa) pikselikoolla 294 m<sup>2</sup> (ylhällä), 591 m<sup>2</sup> (keskellä) ja 1182 m<sup>2</sup> (alhaalla). Vasemmalla on ensimmäinen 5-vuotiskausi ja oikealla toinen 5-vuotiskausi.

**Taulukko 6.** Optimoinneissa muodostettuja käsittely-yksiköitä kuvaavat tunnuksat eri pikselikoolla.

Tunnus	Pikselin koko m <sup>2</sup>					
	294		591		1182	
	1. kausi	2. kausi	1. kausi	2. kausi	1. kausi	2. kausi
Lukumäärä	32	11	16	6	15	7
Minimikoko, ha	0,03	0,15	0,35	0,47	0,59	0,83
Maksimikoko, ha	39,87	65,42	89,00	63,63	47,76	102,84
Kokonaisala, ha	121,64	138,81	123,83	120,76	113,48	127,66
Keskiarvo, ha	3,80	12,62	7,74	20,13	7,57	18,24
Keskihajonta, ha	7,83	21,50	21,15	27,73	11,65	34,61

mäisellä kaudella (kuva 6). Toisella kaudella suurin osa hakkuista onkin nimenomaan uudistushakkuita. Pikselikokojen välillä on eroja hakkuiden sijoittumisessa, mikä osittain määräytyy sen mukaan, kuinka ensimmäisen kauden hakkuut sijoittuvat.

Yksittäisiä, hakkaamattoman metsän keskellä sijaitsevia hakkuupikseleitä ei ole missään suunnitelmassa paljoa. Eniten hyvin pieniä hakkuukohteita on tullut pienimmällä pikselikoolla ensimmäiselle 5-vuotiskaudelle. Jonkin verran enemmän on harvennushakkuualueen keskellä sijaitsevia yksittäisiä uudistushakkuupikseleitä.

Suunnitelmissa on myös hakkuualueiden sisällä olevia hakkaamattomia pikseleitä. Nämä eivät suunnitelman toteutuksen kannalta ole yhtä ongelmallisia kuin yksittäiset hakkuupikselit hakkaamattoman alueen keskellä, sillä esim. hakkaamaton pikseli harvennuskuvion keskellä tarkoittaa yleensä kohtaa, jossa ei ole harventamista, eikä pikselin käsittelemättä jättäminen ole ongelma. Uudistusalueen sisällä olevia yksittäisiä hakkaamattomia pikseleitä on jonkin verran jokaisella pikselikoolla. Nämä voivat olla suunnitelman toteutuksen kannalta suurempi ongelma kuin harvennusalueella olevat hakkaamatta jäävät pikselit. Toisaalta ko. pikseleiden hakkaamatta jättäminen voi olla ”oikeakin” ratkaisu, jos kyseessä on esim. reippaasti muuta metsikköä nuorempi kohta.

Optimoinnissa muodostettujen käsittely-yksiköiden lukumäärä oli suurin pienimmällä pikselin koolla (294 m<sup>2</sup>) molemmilla suunnittelukausilla (taulukko 6). Sekä käsittely-yksikön keskikoko että sen minimikoko olivat selkeästi pienimmät pienimmällä pikselikoolla molemmilla suunnittelukausilla. Suurimmat erot kahden suurimman pikselikoon välillä olivat käsittely-yksiköiden minimi- ja maksimikoos-

sa. Suurimman pikselikoon (1182 m<sup>2</sup>) minimikoko oli lähes kaksi kertaa niin suuri kuin keskimmaisen pikselikoon (591 m<sup>2</sup>) molemmilla suunnittelukausilla. Ensimmäisellä kaudella maksimikoko oli suurin keskimmäisellä pikselikoolla ja toisella kaudella suurimmalla pikselikoolla. Käsittely-yksiköiden yhteispinta-ala oli ensimmäisellä kaudella suurin keskimmäisellä pikselikoolla ja toisella kaudella pienimmällä pikselikoolla. Käsittely-yksiköiden kokonaispinta-ala molemmat kauden mukaan lukien oli suurin pienimmällä pikselinkoolla (260,45 ha) ja pienin suurimmalla pikselikoolla (241,14 ha).

## 5 Tarkastelua

Tutkimuksessa osoitettiin, että nykyisillä inventointi- ja suunnittelumenetelmillä voidaan tehdä suunnittelua, jossa ei käytetä lainkaan perinteisiä kiinteärajoja metsikkökuvioita. Toisaalta tulokset osoittivat, että saatua kuviointia tulee joissakin tapauksissa ”siistiä”, jotta suunnitelma olisi kaikilta osin toteutuskelpoinen. Siistiminen voidaan tehdä esimerkiksi erilaisin suodatusmenetelmin, jotka poistavat esim. yksinäiset hakkuupikselit. Toinen vaihtoehto on kehittää edelleen spatiaalisen optimoinnin tavoitemuuttujia ja itse optimointialgoritmeja niin, että käsittely-yksiköiden sijoittuminen on kaikilta osin tyydyttävää. Nämä kehittämistehtävät jäävät kuitenkin tulevien tutkimuksien varaan, sillä tässä tutkimuksessa ei vielä ollut tavoitteena kehittää menetelmää käytännön metsätalouden tarpeisiin, vaan ainoastaan selvittää, mihin nykyisillä inventointi- ja suunnitteluvälineillä päästään.

Pikselikoko vaikutti siten, että mitä pienempi oli

laskentayksikön koko, sitä sirpaleisempaa oli käsittelyjen sijoittuminen. Tämä johtuu luultavasti osittain siitä, että pienellä pikselikoolla naapuripikseleiden metsikkötunnukset eroavat eniten, minkä vuoksi naapuripikseleille tuotettu käsittelyvaihtoehtojen valikoima eroaa myös. Jos metsässä on pienipiirteistä vaihtelua, tiheässä tai uudistuskypsässä metsikössä voi olla runsaastikin pikseleitä, joille simulaattori ei ole tuottanut yhtään hakkuuvaihtoehtoa. Näissä tapauksissa alueesta ei voi optimoinnissa tehdä yhtenäistä käsittelyaluetta. Tältä ongelmalta vältyttäisiin sallimalla pienalueen uudistushakkuu jo selvästi ennen uudistuskypsyyksiteoreiden täyttymistä ja simuloimalla harvennuksia silloinkin, kun leimausraja ei ylitä.

Pienen pikselikoon sirpaleistava vaikutus johtuu osittain myös siitä, että esim. tie ja kaikki muutkin kapeat metsäpeitteettömät kohteet poistavat pikseleiden naapurisuuden sitä useammin, mitä pienempää pikselikokoa käytetään. Tästä ongelmasta päästään eroon käyttämällä laajempaa tai toisella tavalla määriteltyä naapuristoa kuin tässä tutkimuksessa.

Toisaalta päätelmää, että tässä tutkimuksessa käytetyt menetelmät tuottavat sirpaleisia käsittelykuvioita, ei voi yleistää. Heinonen ym. (2007) havaitsivat, että jos metsä muodostuu homogeenisistä metsikkökuvioista, pikseleihin ja spatiaaliseen optimointiin perustuva suunnittelu tuottaa aivan yhtä kelvollisia käsittely-yksiköitä kuin kiinteärajaisia kuvioita käyttävä suunnittelu. On huomattava, että tässä tutkimuksessa suunnitelma tehtiin hyvin heterogeeniselle metsälle, jossa ei ollut montaakaan selkeää kuviota. On luultavaa, että myös kuvioihin perustuvassa suunnittelussa hakkuualueiden sisään jäisi kohtia, joissa ei ole hakattavaa.

Pikselikoko vaikutti myös niin, että metsän käyttö oli tavoite- ja rajoitemuuttujien arvojen perusteella sitä tehokkaampaa, mitä pienempää pikselikokoa laskelmissa käytettiin. Tämä on hypoteesin mukainen tulos, sillä suureneva laskentayksikön koko kaventaa suunnittelun mahdollisuuksia optimoida metsän käyttöä. Jos koko laskentayksikköä tulee käsitellä samalla tavoin, on suunnitteluongelma sitä rajoitetumpi, mitä suurempi on laskentayksikön koko. Käsittely-yksiköiden koko ja muoto vaikuttavat korjuukustannuksiin. Näitä tekijöitä, jotka saattavat vaikuttaa eri pikselikokojen tehokkuuteen, ei kuitenkaan otettu huomioon vielä tässä tutkimuksessa.

Osa pienen pikselikoon paremmuudesta saattaa johtua myös puustotunnusten tulkintamenetelmästä. Jos esim. keskiläpimitan ennustamisen virhevaihtelu suurenee pikselikoon pienentyessä, on tästä seurauksena sitä suurempi yliarvio esim. puuston tilavuudessa, mitä pienempi on pikselikoko. Tämä johtuu siitä, että tilavuus kolmiulotteisena tunnuksena on verrannollinen yksiulotteisen tunnuksen (esim. läpimitta tai pituus) kolmanteen potenssiin. Ongelmaa voitaisiin pienentää käyttämällä keskitunnusten esimoinnissa esim. tilavuuskalibrointia.

Puustotunnusten tulkintaa kehitettäessä on myös pidettävä mielessä kahden erilaisen metsikön rajalla olevat pikselit. Tässä tutkimuksessa käytetyssä menetelmässä rajapikseleiden puustotunnukset saattavat tulla koealoilta, jotka eivät muistuta kumpaakaan rajapikselin metsikköä. Minimiraatkaisu rajapikseliongelmaan on se, että menetelmä tunnistaa selkeät rajapikselit ja esim. muuttaa pikselin sijaintia niin, että se on kokonaan jomman kumman metsikön puolella. Rajapikseliongelma päästäisiin myös käyttämällä tulkintayksikköinä kuusikulmioiden sijasta segmentoinnin tulosta.

Kuten moniulotteisessa mallinnuksessa yleensä, käytettävän koealaotoksen laatu on tulosten tarkkuuden kannalta kriittinen. Estimoitavia puustotunnuksia on puulajeittaisessa estimoinnissa niin paljon, että koeala-aineisto ei voi sisältää kaikkia mahdollisia puustotunnusten yhdistelmiä. Tästä seuraa, että osalla soluista tulos väistämättä perustuu ekstrapolointiin tai sijaitsee interpolointiavaruuden reunojen läheisyydessä, missä ennustustarkkuus on interpolointiavaruuden keskiosaa heikompi. Näissä tapauksissa ennusteen laatu on tavallista heikompi ja voi syntyä tunnuksia tai niiden yhdistelmiä, jotka eivät todellisuudessa ole mahdollisia.

## Kirjallisuus

- Baskent, E.Z. & Jordan, G.A. 2002. Forest landscape management modelling using simulated annealing. *Forest Ecology and Management* 165: 29–45.
- Beasley, J.E. 1993. Lagrangean relaxation. *Julkaisussa: Reeves, C.R. (toim.). Modern heuristic techniques for combinatorial problems.* John Wiley & Sons, Inc., New York. s. 242–300.

- Bettinger, P., Sessions, J. & Boston, K. 1997. Using tabu search to schedule timber harvests subject to spatial wildlife goals for big game. *Ecological Modelling* 42: 111–123.
- Heinonen, T. & Pukkala, T. 2004. A comparison between one- and two-neighbourhoods in heuristic search with spatial forest management goals. *Silva Fennica* 38(3): 319–332.
- & Pukkala, T. 2007. The use of cellular automaton approach in forest planning. *Canadian Journal of Forest Research* 37(11): 2188–2200.
- , Kurttila, M. & Pukkala, T. 2007. Possibilities to aggregate raster cells through spatial optimization in forest planning. *Silva Fennica* 41(1): 89–103.
- Hoganson, H.M. & Borges, J.G. 1998. Using dynamic programming and overlapping subproblems to address adjacency in large harvest scheduling problems. *Forest Science* 44(2): 526–538.
- & Rose, D.W. 1984. A simulation approach for optimal timber management scheduling. *Forest Science* 30(1): 220–238.
- Holmgren, P. & Thuresson, T. 1997. Applying objectively estimated and spatially continuous forest parameters in tactical planning to obtain dynamic treatment units. *Forest Science* 43(3): 317–326.
- Hyypä, J. & Inkinen, M. 1999. Detecting and estimating attributes for single trees using laser scanner. *The Photogrammetric Journal of Finland* 16: 27–42.
- Junttila, V., Maltamo, M. & Kauranne, T. 2008. Sparse Bayesian estimation of forest stand characteristics from ALS. *Käsikirjoitus*.
- Kurttila, M., Pukkala, T. & Loikkanen, J. 2002. The performance of alternative spatial objective types in forest planning calculations: a case for flying squirrel and moose. *Forest Ecology and Management* 166(1–3): 245–260.
- Lu, F. & Eriksson, L.O. 2000. Formation of harvest units with genetic algorithms. *Forest Ecology and Management* 130(1): 57–67.
- Maltamo, M., Eerikäinen, K., Pitkänen, J., Hyypä, J. & Vehmas, M. 2004. Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. *Remote Sensing of Environment* 90: 319–330.
- Meza, J.C., Oliva, R.A. & Hough, P.D. 2007. OPT++: An object oriented toolkit for nonlinear optimization. *ACM Transactions on Mathematical Software*. 33(2).
- Næsset, E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment* 80: 88–99.
- 2004. Accuracy of forest inventory using airborne laser scanning: evaluating the first nordic full-scale operational project. *Scandinavian Journal of Forest Research* 19(4): 554–557.
- Packalén, P. & Maltamo, M. 2007. The k-MSN method in the prediction of species specific stand attributes using airborne laser scanning and aerial photographs. *Remote Sensing of Environment* 109: 328–341.
- Pukkala, T. 2004. Monikäytön suunnitteluohjelma Mon-su. Ohjelmiston toiminta ja käyttö. Joensuun yliopisto. 72 s.
- & Heinonen, T. 2006. Optimizing heuristic search in forest planning. *Nonlinear Analysis: Real World Applications* 7(2006): 1284–1297.
- Strange, N., Meilby, H. & Jellesmark, T.B. 2002. Optimization of land use in afforestation areas using evolutionary self-organization. *Forest Science* 48(3): 543–555.
- Suvanto, A., Maltamo, M., Packalén, P. & Kangas, J. 2005. Kuviokohtaisten puustotunnusten ennustaminen laserkeilauksella. *Metsätieteen aikakauskirja* 4(2005): 413–428.
- Tipping, M.E. 2001. Sparse Bayesian learning and the relevance vector machine. *Journal of Mathematical Learning Research* 1 (Sep. 2001): 211–244.
- Tuominen, S., Holopainen, M. & Poso, S. 2006. Multi-phase sampling. *Julkaisussa: Kangas, A. & Maltamo, M. (toim.) 2006. Forest inventory – methodology and applications. Springer Science & Business Media. s. 235–252.*
- Wang, G., Poso, S., Waite, M.-L. & Holopainen, M. 1998. The use of digitized aerial photographs and local operation for classification of stand development classes. *Silva Fennica*, 32: 215–225.

## 25 viitettä