

# **SUURIMITTAKAAVAINEN KARTOITUS SATELLIITTIKUVILTA**

14.5.2007

Maa-57.270 Fotogrammetrian, kaukokartoituksen ja kuvatulkinnan seminaari  
Kaukokartoituksen seminaarityö  
Pyy Kettunen  
61193R

# Sisällysluettelo

|   |    |
|---|----|
| I Johdanto . . . . .                              | 3  |
| II Fotogrammetrinen kartoitus . . . . .           | 3  |
| 1. Topografinen kartoitus . . . . .               | 3  |
| 2. Korkeuskartoitus kuvakolmikolta . . . . .      | 5  |
| III Automatisoituja kartoitusmenetelmiä . . . . . | 7  |
| 1. Rakennukset . . . . .                          | 7  |
| 2. Tiet . . . . .                                 | 8  |
| 3. Muutosten havaitseminen . . . . .              | 10 |
| IV Yhteenveto . . . . .                           | 11 |
| Lähteet   |    |
| Viitteet  |    |

# I Johdanto

MetriLuokan erotuskykyyn pystyvien kaukokartoitussatelliittien määrä on lisääntynyt viime vuosina tasaisesti ja uusien, entistä tarkempiin havaintoihin kykenevien kaukokartoitusinstrumenttien laukaisuja on lähitulevaisuudessa suunnitteilla lukuisia. Parhaiden sensorien alle puolen metrin erotuskyky tuo satelliittikuvat kilpailemaan perinteisesti korkeisiin resoluutioihin yltäneiden ilmakuvakameroiden sovellusalueille. Satelliittikuvien käyttökohteet tulevat lisääntymään entistä vaativampiin yhteyksiin, joista yksi keskeisimmistä ja laajimmin harjoitetuista on maaston suurimittakaavainen kartoitus. Suurilla mittakaavoilla tarkoitetaan tässä vähintään mittakaavaa 1:25 000, joita vastaavat tyypillisesti kansallisten karttalaitosten topografiset kartat, esimerkiksi Suomen Maanmittauslaitoksen peruskartta 1:25 000.

Suurimittakaavaisten kartojen tarkkuusluokka on niin korkea, että resoluution kasvattaminen ei suoraan kerro kartoitusmahdollisuuksista vastaavalta kuvalta: riippuen kuvauskulmasta korkeat ja laajat kohteet voivat peittää toisia, jotka muutoin olisivat hyvin kartoituksen piirissä. Lisäksi tarkoilla kartoilla kuvataan monia maassa liikkuvalla havainnoijalle oleellisia kohteita, joiden havaitseminen ilmasta käsin on esimerkiksi niiden kapeuden vuoksi hyvin hankalaa. Tällaisia kohteita ovat tyypillisesti lanka-aidat ja sähkölinjat pylväineen. Kartoituksen tarkkuusvaatimus on myöskin huomattava, kun kartoittajan tulisi kyetä osoittamaan kohteet paikalleen muutaman metrin virherajan sisään kartan sijaintiluotettavuuden ylläpitämiseksi. Muun muassa näiden suurimittakaavaisen kuvaltakartoituksen ongelmien vuoksi on tutkimus korkearesoluutioisten satelliittikuvien kartoituspotentiaalista ollut viime aikoina vilkasta.

Tässä työssä käsitellään tarkkaa kartoitusta satelliittikuvilta kahdesta näkökulmasta: ihmiskartoittajan suorittamana ja kuvankäsittelyn automaation keinoin tehtynä. Käsittely perustuu viiteen kaukokartoitusalan aikakausjulkaisun artikkeliin ja tarkoituksena on valottaa pienimuotoisesti tutkimuksen ja sovelluksen tilannetta suurimittakaavaisessa satelliittikuvakartoituksessa. Luvussa kaksi kerrotaan ihmiskartoittajan suorittaman satelliittikuvakartoituksen mahdollisuuksista, jotka nojaavat vahvasti operatiivisesta ilmakuvakartoituksesta johdettuihin menetelmiin: tarkastellaan satelliittikuvakartoituksen tarkkuutta Iso-Britannian karttalaitoksen aineistoon verraten ja esitellään satelliittikuvien erityisesti tukeman useamman kuvan käyttöön perustuvan kolmiulotteisen kartoitusmenetelmän tutkimus. Kolmannessa luvussa esitetään puoliautomaattisia tai automaattisia piirreirrotusmenetelmiä, jotka pyrkivät jokainen jonkin tietyn yleisen yksittäisen piirteen kattavaan kartoitukseen satelliittikuvalta. Tarkastellaan automaattisen kuvankäsittelyn menetelmiä rakennusten, teiden ja maanpeiton kartoitukseen. Neljännessä luvussa vedetään yhteen opittuja aiheita ja niiden luomia mahdollisuuksia satelliittikuvakartoitukselle.

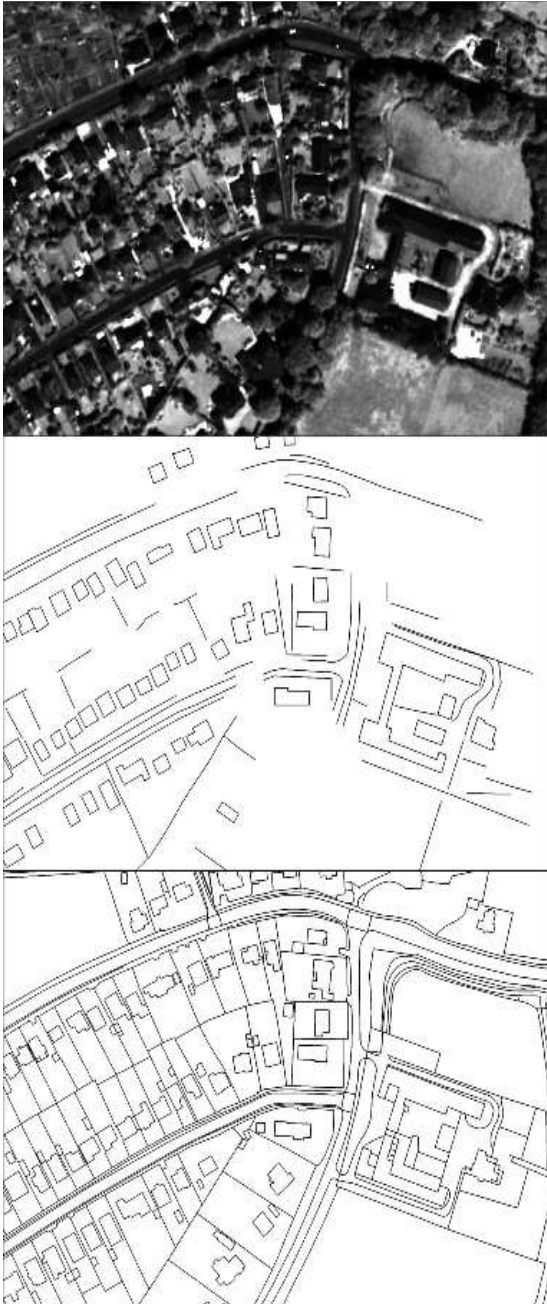
## II Fotogrammetrinen kartoitus

### II.1. Topografinen kartoitus

Holland, Boyd ja Marshall (2006) ovat tekemässään tutkimuksessa selvittäneet QuickBird-satelliitin kuvien käyttämistä Iso-Britannian kansallisen karttalaitoksen vaatimusten mukaiseen operationaaliseen suurimittakaavaiseen kartoitukseen [1]. Topografisen kartoituksen näkökulmasta tutkimus tehtiin koalueella Christchurchissä ja käytetty kuvatuote oli pankromaattinen QuickBird Basic, jonka nadiirierotuskyky on 60 cm (www.digitalglobe.com, 2007). Kuvat orto-oikaistiin kartoitusta varten ERDAS IMAGINE -ohjelmaa käyttäen. Tarkkuuden määrittämiseksi haettiin vertauspisteet Ordnance Surveyn OSMasterMap-tietokannasta ja niille korkeudet OS LandForm PROFILE -korkeusmallista. Vertauspisteiden vaakatarckkuudeksi keskimääräisen neliöllisen virheen neliöjuurena saatiin koalueen orto-oikaistulla kuvalla 2,2 metriä ja korkeuden tarkkuus 10 metrin hilassa oli 2,5 metriä. Lisätarkkuuden hankkimista satelliittipaikannuksen tai maastomittauksen keinoin ei nähty tutkimuksessa tarpeelliseksi.

Kattavasti kartoitetuissa maissa kuten Iso-Britanniassa on topografisen kartoituksen päätehtävänä havaita ja

rekisteröidä maastossa tapahtuneita muutoksia. Jotta selvitetäisiin Christchurchin QuickBird-kuvan soveltuvuutta tähän tehtävään, annettiin orto-oikaistu satelliittikuva Ordnance Surveyn kokoneiden kartoittajien analysoitavaksi samoin kriteerein, joilla fotogrammetrista kartoitusta tehdään ilmakuvilta. Kuvaa käytettiin kartoitukseen yksinään. Kartoittajien tuli kartoittaa kuvalta tiet, rautatiet, urat ja polut, rakennukset, kasvillisuusrajat, vesistöt, aallomurtajat ja peltojen rajat karttalaitoksen kuvausohjeiden mukaisesti kaupunki-, maaseutu- ja erämaa-alueilla vastaavissa mittakaavoissa 1:1250, 1:2500 ja 1:10000. Lisäksi vertailuun otettiin mukaan pienemmät mittakaavat 1:25000 ja 1:50000 kuvausohjeineen, koska niiden yleistys suoritetaan eri tavoin ja käyttäjäryhmien tarpeet ovat erilaiset kuin suuremmissa mittakaavoissa, jotka palvelevat ensisijaisesti ammattikäyttöä.



*Kuva 1: QuickBird-satelliittikuva, OS:n kuvausohjeiden mukainen kartoitustulos ja OS MasterMap-vektoritietokanta Christchurchin koekuvan osan alueelta [1]*

Satelliittikuvakartoituksen tuloksena saatua vektorikarttaa verrattiin OS MasterMap-vektoritietokantaan aluksi silmämääräisesti tutkien. Kuvassa 1 on osa koalueesta satelliittikuvana, satelliittikuvakartoituksena ja vertaustietokannasta poimittuna. Yleisesti havaittiin, että rakennusten seinälinjat olivat tulleet kartoitetuksi paljon vertaustietokantaa yleistetympin. Tiet oli saatu kartoitettua vertaustietokantaa vastaavasti, mutta jalkakäytävän reunakiveyksen paikan määrittäminen oli todettu usein hankalaksi, mistä syystä nämä kohteet näkyvät kartoituksessa varsin epäjatkuvina.

Aiemmin luetellut kartoituskohteet käytiin läpi järjestelmällisesti vertaamalla kunkin vertausmittakaavan kuvausohjeita kohteen määrittävyyteen satelliittikuvalla ja tulokset kerättiin taulukkoon. Todettiin, että kaksiajorataiset tiet, aallomurtajat, padot, merkittävät maastonmuutokset ja kasvillisuus ovat selvästi havainnoitavissa kaikkien mittakaavojen kuvausvaateisiin nähden riippumatta niiden sijainnin suosiollisuudesta kartoitukselle. Mittakaavasta 1:2500 lähtien myös teiden näkyvyys vastasi vaateita. Siirryttäessä 1:10000 -kuvausohjeisiin saatiin kartoitustarkkuuden piiriin muut kuin asuinrakennukset, lentokentät, rautatiet, asuntovaunut, louhokset liukuhihnoineen sekä vesistöt. Niin sanotuista siviilimittakaavoista mahdollisesti 1:25000 lisäksi asuinrakennusten vaaditun kartoitustarkkuuden. Mittakaavassa 1:50000 saatiin kartoitusvaateiden piiriin vielä keskeisimmät kiinteistö- ja pellonrajat. Sijainnin olosuhteista riippuvaisesti saatiin kaikissa mittakaavoissa kartoitettua urat ja polut. Täysin mahdottomiksi havaittaviksi jäivät sähkölinjat ja puhelinkopit.

Silmämääräistä tarkemman tutkimustiedon saamiseksi mitattiin satelliittikuvakartoituksen geometristä tarkkuutta vertaamalla kohteiden sijainteja OS MasterMap -sijainteihin. Vertailukohteina käytettiin rakennusten nurkkia ja aitojen kulmauksia. Mittauksen tuloksena saatiin neliöllisen keskivirheen neliöjuuren arvoiksi rakennuksille noin 2,3 metriä ja aidoille 1,6 metriä, minkä todettiin sijoittuvan OS MasterMapin maaseutu- ja erämaamittakaavojen tarkkuuksien välille 1,1 - 4,1 metriä.

Koska satelliittikuvakartoitus todettiin sopivimmaksi pienimmässä mittakaavassa, suoritettiin niiden osalta vielä vertailu perinteiseen ilmakuvakartoituksen kanssa keskittyen näissä mittakaavoissa tyypillisesti tärkeisiin kohteisiin, jotka

olivat tiet ja rautatiet, rakennukset, muut rakenteet, pellonrajat, kasvillisuus, vesistöt ja muinaisjäänteet. Tiedonkeräys suoritettiin orto-oikaistujen QuickBird-kuvien lisäksi 25 cm erotuskyvyn väri-ilmakuvilta ja kummassakin keräystavassa laskettiin havaittujen, määrättyjen ja määräämättömiksi jääneiden kohteiden lukumäärät mittakaavojen 1:25000 ja 1:50000 kuvausohjeita noudattaen kolmessa määräysluokassa. Määräysluokat olivat karttamerkin määräämisen mahdollistava kohdetunnistus, kohteen tyyppitunnistus merkkiluokassaan ja lisäarvotietoa tarjoava tunnistus. Vertailun tuloksena saatiin, että lähes kaikki kohdetyypit saadaan kartoitettua kohdetunnistuksen tarkkuudella sekä satelliitti- että ilmakuvalta molemmissa siviilimittakaavoissa satelliitti/ilmakuva -tunnistusprosenttien oltua 92/97 ja 95/100. Tyyppitunnistuksessa ilmakuvakartoitus on selvästi tarkempaa tunnistusprosenttien oltua 68/84 ja 70/76 ja lisäarvotunnistuksessa ero on vielä reilumpi tunnistusprosentteilla 44/88 ja 52/62.

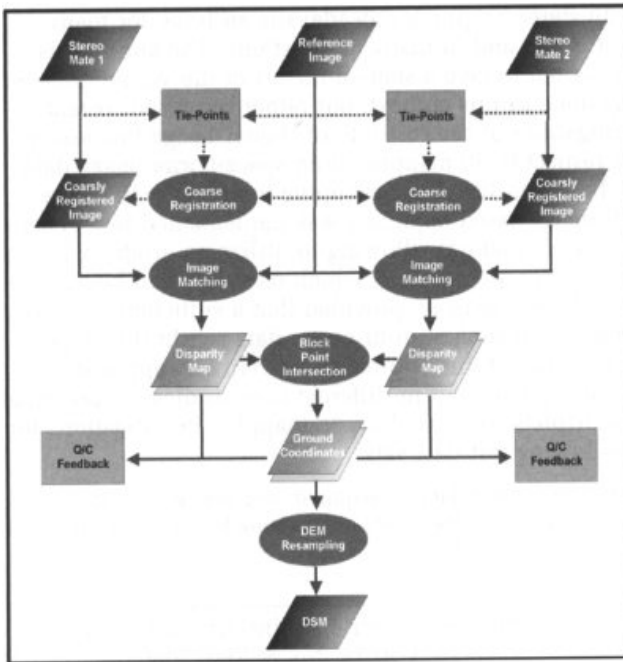
Yhteenvetona tuloksistaan Holland, Boyd ja Marshall toteavat, että käytetyt QuickBird-kuvat voivat toimia topografisen kartoituksen lähteenä OS MasterMap -mittakaavassa 1:10000 ja topografista dataa saadaan irrotettua vielä mittakaavassa 1:6000. Ohuet viivamaiset kohteet olivat ensisijaisen satelliittikuvakartoituksen selvin puute, mitä varten tarvittaisiin lisätiedon keruuta vaihtoehtoisin menetelmin tai kuvausohjeita olisi muutettava epätarkemmiksi, mikä ei tulle kysymykseen. Toissijaisena lähteenä korkearesoluutioisten satelliittikuvien todettiin kuitenkin olevan ensiluokkainen, joskin varsin kallis.

## II.2. Korkeuskartoitus kuvakolmikolta

Maaston korkeuden kartoitus on ilmakuvausalkuajoista lähtien perustunut fotogrammetriseen kartoitukseen stereokuvaparilta. Stereokuvaparin menetelmää on sovellettu laajasti myös satelliittikuville ja korkeusmallien keräystä on automatisoitu pitkälle eritoten pieniä mittakaavoja silmällä pitäen. Topografisen kartoituksen yksityiskohtainen korkeuskäyräesitys vaatii kuitenkin edelleen ihmisoperaattorin toimintaa yhtenäisen ja havainnollisen korkeusesityksen aikaansaamiseksi ja korkeuskartoitus tehdään vielä ensisijaisesti ilmakuvalta. Korkearesoluutioisten satelliittikuvien parantunut saatavuus on kuitenkin tuonut ajankohtaiseksi satelliittikuvien käyttämisen topografisen korkeuskartoituksen suorittamiseen. Stereokartoituksen ongelmana satelliittikuvilla on usein tarkkuuden riittämättömyys joko vaak- tai korkeusulottuvuudessa kuvaparin geometriasta ja satelliitin ilmakuvaus verrattuna heikosta erotuskyvystä johtuen. Hannes Raggam (2006) on pyrkinyt ratkaisemaan tätä ottamalla käyttöön kolmannenkin satelliittikuvan, mikä ei useinkaan ole kuvaparia vaikeampi hankinta. Artikkelissaan hän kuvaa menetelmän korkearesoluutioisen satelliittikuvakolmikolon käyttöön maaston pinnanmuotojen kartoituksessa [2].

Raggamin kuvaamassa kolmikuvakartoituksessa suoritetaan kuvakolmikolon kuville aluksi muunnos vertauskuvaksi valitun kuvan geometriaan. Tämä rekisteröinniksi nimetty orientointi tehdään liitospisteitä käyttäen määritettynä lineaarisena muunnoksena. Seuraavaksi sovitetaan kuvat yhteen pareittain vertauskuvan kanssa laajennetun piirrektorisoroitituksen mukaan, missä piirrektori koostuu konvoluutio-, varianssi- ja muista vastaavista suotimista. Oleellisena piirteenä Raggam mainitsee ristikorrelaatiokerroimen. Kuvasovituksen luotettavuuden määrittämiseksi tehdään vielä takaisinsovitus, josta laskettua pikselin paikkaa verrataan alkuperäisen pikselin sijaintiin. Sijaintien erotus kertoo sovituksen tarkkuuden. Toinen pisteittäinen sovituksen luotettavuusmitta on ylimääritystapauksessa tarvittavasta pienimmän neliösumman tasoituksesta saatava pisteresiduaali. Lopuksi laskettuja sovitustuloksia käytetään kuvapisteitä vastaavien maanpinnan pisteiden paikallistamiseksi, mikä toteutetaan pienimmän neliösumman eteenpäinleikkauksena. Tässä laskennassa voidaan takaisinsovituksessa epäluotettaviksi todetut liitospisteet jättää ottamatta huomioon, mikäli pisteitä jää laskentaan riittävä määrä eli vähintään yksi, jolloin tapaus kutistuu normaaliksi eteenpäinleikkaukseksi. Näin on liitospisteiden avulla saatu laskettua epäsäännöllinen maanpinnan pistejoukko, jonka kolmiulotteiset koordinaatit tunnetaan. Tuloksena on siis oleellisesti korkeusmalli, johon jääneet aukot täytyy vielä paikata sopivalla interpoloinnilla, jonka jälkeen sitä voidaan käyttää esimerkiksi korkeuskäyrien piirtoon. Kuva 2 esittää kolmikuvakartoituksen prosessikaavion.

Kehitettyä kolmikuvakartoitusta on tutkittu monissa eri käytännön tilanteissa, joista Raggam esittää artikkelissaan kolme. Niistä ensimmäisessä käytettiin SPOT 5 -satelliitin Barcelonan ympäristöstä lähekkäisinä ajanhetkinä kuvaamaa kuvakolmikkoa. Toisessa koekäytössä kuvakolmikko koostui kolmesta eri aikoina Itävallan Alpeilta



Kuva 2: Kolmikuvakartoituksen prosessikaavio [2]

kaikista pisteistä laskettiin kuvaamaan eri kuvaparien välisiä kuvansovituksen luotettavuuseroja, ja näin havaittiin yleisesti, että eteen- ja taaksepäin otettujen kuvien muodostama stereokuvapari oli liitospisteiltään kuvapareista luotettavin. Kuvakolmikkoa käytettäessä jäi pudotettujen pisteiden osuus parastakin stereokuvaparia huomattavasti pienemmäksi lukuunottamatta maaseutumaista aluetta, joten tutkimuksen asettelussa muodostettu teoria

|               | Area 1 (rural) |        | Area 2 (mountainous) |        | Area 3 (Urban) |        |
|---------------|----------------|--------|----------------------|--------|----------------|--------|
|               | Mean           | Std.D. | Mean                 | Std.D. | Mean           | Std.D. |
| HRS fwd/bwd   | 1.5            | 4.9    | 4.4                  | 24.1   | 9.1            | 8.2    |
| HRG/HRS fwd   | 3.6            | 5.7    | 5.0                  | 7.1    | 10.2           | 9.2    |
| HRG/HRS bwd   | 0.1            | 5.4    | -0.7                 | 8.0    | 6.3            | 7.9    |
| Image triplet | 1.7            | 4.8    | 1.8                  | 6.5    | 8.2            | 8.3    |

Taulukko 1: Kuvakolmikokartoituksen korkeustarkkuus Barcelonan SPOT-5 kuvalla [2]

vuosina 1987, 1992 ja 1997 Alpeilta otettua SPOT-kuvaa, joiden nadiirikulmat vastaavassa järjestyksessä olivat -0,6, -22,3 ja 20,3 astetta. Vertauskuvaksi otettiin vuoden -87 nadiirikuva. Kuvansovitus ja eteenpäinleikkaukset tehtiin jälleen kuvapareille vuorotellen, ja eteenpäinleikkaukseen hyväksyttiin pisteet, joiden takaisinsovituserotus oli enintään 1,5 pikseliä ja pisteresiduaali enintään 1 pikseli. Kuvakolmikokartoituksen eteenpäinleikkauksipisteiden pudotusprosentiksi muodostui noin 9, joka oli vajaat kaksi kolmasosaa parhaan stereokuvaparin tuloksesta. Koko laskennasta saadun korkeusmallin korkeuksia verrattiin vertauskorkeusmalliin ja todettiin kuvakolmikolta lasketun korkeusmallin vastaavan vertausmallia kuvaparimalleja paremmin erotuksen keskihajonnalla mitattuna, eikä erotuksen keskiarvokaan jäänyt paljoa parasta stereoparia suuremmaksi.

Kreikan ja Portugalin kokeissa muodostettiin kuvakolmikot IKONOS-stereokuvaparista ja pankromaattisesta QuickBird-kuvasta, jotka oli valittu tavallisessa stereokuvakartoituksessa hankaliksi tapauksiksi: Kreikassa kuvalla osui syvä jokirotko ja Portugalissa IKONOS-kuvilla oli merkittävän kokoisia pilviä. Kuvat oli otettu kummassakin tapauksessa muutaman viikon aikajaksolla. Vertauskuvaksi otettiin Kreikassa eteenpäin katsova IKONOS-kuva ja

otetusta SPOT-kuvasta suurinpiirtein SPOT-5:ttä vastaavin kuvakulmin. Kolmas testi tehtiin kahdella Kreikassa ja Portugalissa sijaitsevalla alueella, ja kuvakolmikot koottiin IKONOS-stereokuvaparista sekä pankromaattisesta QuickBird-kuvasta.

Barcelonan kolmikuvakoe suoritettiin kolmelta yhdellä ylilennolla kuvatulta SPOT-5 kuvalta. Yksi SPOT-5:n kameroista ottaa kuvaa nadiiriin 2,5 metrin erotuskyvyllä ja kaksi  $\pm 20$  asteen nadiirikulmaan asetettua kameraa tuottavat 5 m x 10 m resoluutioisia eteen- ja taaksepäin viistoja kuvia. Vertauskuvana käytettiin nadiirikuvaa, joten viistosta otettujen kuvien rekisteröinti vertauskuvaa vastaaviksi tehtiin ylinäytteistämällä ne 2,5 metrin pikselikokoon. Tulosten vertausaineistoina käytettiin numeerista 15 m hilan korkeusmallia ja ilmakuviasta tuotettua ortokuvamosaiikkia 0,5 metrin pikselikoolla. Kuvansovitus ja eteenpäinleikkaukset tehtiin vuorotellen eri kuvapareille, ja eteenpäinleikkauksessa käytettiin mukaan otettavan liitospisteiden takaisinsovituserotuksen ja pisteresiduaalin kynnyksinä yhtä pikseliä. Eteenpäinleikkauksessa pois pudotettujen pisteiden osuus

kuvakolmikolla suoritettua eteenpäinleikkauksen vankkuudesta osoittautui todeksi. Tarkasteltaessa laskennassa lopullisesti saadun korkeusmallin tarkkuutta todettiin, että kuvakolmikokartoituksen käyttö johti stereokuvapareja tarkempaan korkeusinformaatioon: niin korkeusvirheen keskiarvo kuin keskihajontakin jäivät paria olosuhteista johtuvaa poikkeusta lukuunottamatta kuvakolmikolla pienemmiksi. Korkeusvirheen tulostaulukko on nähtävissä taulukossa 1.

Itävallan kokeessa käytettiin kolmea

Portugalissa nadiirikuvauksen QuickBird-kuva. Kummallakin testialueella saatiin liitospisteiden koordinaatit kenttämittauksin satelliittipaikannuksella, koska sopivia korkeusmalleja tai ilmakuvaosaiikkejä ei ollut olemassa riittävällä tarkkuudella, ja käytettiin eteenpäinleikkauksen pisteiden pudotuksen kynnyksarvona yhtä pikseliä sekä takaisinsovituseroitukselle että pisteresiduaalille. Kreikassa kuvakolmikolta pudotettiin laskennasta jälleen ylivoimaisesti vähiten pisteitä, noin 11 %. Korkeusmallitulosten tarkkuutta arvioitiin silmämääräisesti vertausdatan puuttuessa ja todettiin kuvakolmikun kuvaavan maaston pinnanmuodot kuvaparia oikeammin. Portugalissakin kuvakolmikko kykeni vankimpaan kuvansovitukseen eteenpäinleikkauksessa poisjätettyjen pisteiden osuuden ollessa noin 13 % ja kuvakolmikun tuottamat korkeudet todettiin jälleen tarkimmiksi. Erityiseksi tuloksen teki se, että molemmilla IKONOS-stereoparin kuvilla olleiden pilvien ja niiden varjojen vaikutus lopulliseen tulokseen jäi olemattomaksi, vaikka pilvet huononsivat stereoparien tuloksia merkittävästi.

Yhteenvetona Raggam toteaa, että kolmikuvakartoituksen käyttö korkeusmallin luonnissa on kiistattomasti kuvapariin perustuvaa stereokartoitusta tarkempi ja vankempi menetelmä. Kuvansovitus on kuvaparia helpompaa pienemmän kanta-korkeus -suhteen vuoksi ja geometrinen vankkuus säilyy eteenpäinleikkauksessa kuvaparia paremmin ylimäärityksen ansiosta, minkä vuoksi voidaan lisäksi virheellisiksi todetut sovitustulokset poistaa käsittelystä kokonaan.

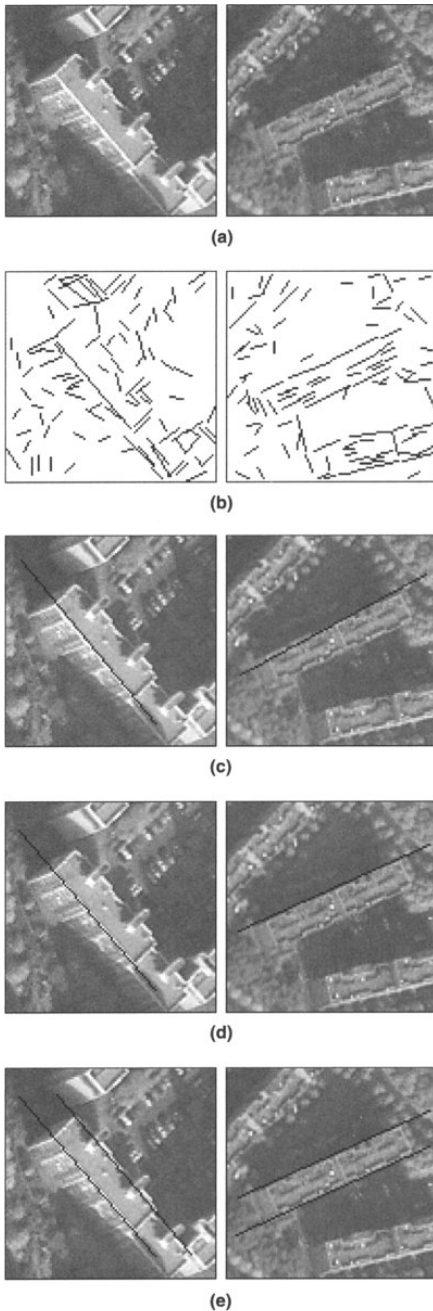
### III Automatisoituja kartoitusmenetelmiä

Ihmistyön kalleuden vuoksi on kuvaltakartoitukseen kehitetty automaatiota niin kauan kuin tietokoneet ovat mahdollistaneet kuvankäsittelyn suorittamista. Suurin osa kehitetyistä algoritmeista toimii korkean erotuskyvyn ilmakuville eli muutamien kymmenien senttimetrin resoluutiotasolla, joten ne eivät useinkaan ole suoraan sovellettavissa satelliittikuvien analysointiin. Erotuskykynsä lisäksi eroavat satelliittikuvat ilmakuista kuvakulmassaan, joka ei läheskään aina ole nadiiri. Näin ollen on satelliittikuvakartoituksen automaation kehittäminen aivan oma tieteenhaaransa, joka onkin tuottanut lukuisan määrän käyttökelpoisia menetelmiä. Tässä esitellään yhdet rakennusten ja teiden erottamiseen pyrkivät algoritmit sekä yksi muutosten havainnointiin kehitetty algoritmi, joita kaikkia on edeltänyt suuri määrä kehitystyötä ja joiden edelleenkehittäminen on vielä varsin tarpeellista. Nämä algoritmit toimivat muutosten havaitsemista lukuunottamatta korkearesoluutioisilla satelliittikuvilla, ja myös muutosten havainnoinnin tarkoituksena on edetä korkearesoluutioisten kuvien hankintaan määritetyiltä alueilta.

#### III.1. Rakennukset

Kim, Lee ja Kim (2006) ovat tutkineet melko suurten suorakulmion muotoisten rakennusten reunaviivojen puoliautomaattista irrottamista satelliittikuvadatasta. He toteavat artikkelinsa johdannossa rakenteiden irrottamisen erittäin hankalaksi tehtäväksi johtuen rakennusten heikoista vasteista kuvilla ja luettelevat pitkän listan aiemmin kehitettyjä menetelmiä, joiden pohjalta lähtivät liikkeelle oman algoritminsa muodostamisessa. Algoritminsa kehittämisen motivaatioksi he esittävät sen tarjoaman vaihtoehdoisen suoritustavan verrattuna moniin muihin toteutuksiin, joita täydentämään esitetty menetelmä on suunniteltu. [3]

Kuva 3 havainnollistaa seuraavassa kuvatun algoritmin toimintavaiheita. Algoritmi tarvitsee lähtötiedokseen rakennuksen katolta osoitetun pisteen, mikä tekee siitä puoliautomaattisen. Artikkelissa kuvatussa tutkimuksessa lähtöpisteet osoitettiin kuvalta käsin, mutta kirjoittajat ehdottavat lähtöosoituksen tekemistä jatkossa esimerkiksi korkeusmallia apuna käyttäen. Aluksi algoritmi rajaa osoitetun pisteen ympäriltä pienen kiinnostusalueen, jolle suoritetaan Burns'n 1986 esittelemä viivaniirrotusalgoritmi. Seuraavaksi irrotetuille viivoille suoritetaan äänestysvaihe, jossa täysi kulma jaetaan ensin sopivaan määrään sektoreita ja lasketaan kuhunkin sektoriin kuuluvien viivojen lukumäärä niiden kuvalta määritettyjen suuntakulmien perusteella. Kunkin viivan antamaa äänimäärää painotetaan suoraan verrannollisesti viivan pituuteen. Kirjoittajat toteavat äänestysmenetelmän olevan ikään kuin Hough-muunnoksen yksinkertaistus kaksiulotteisessa avaruudessa ja perustelevat sen käytön sillä, että varsinaisen rakennuksen reunaviivan läheisyydessä esiintyy yleensä paljon samansuuntaisesti orientoituneita



Kuva 3: Rakennusten reunairrotus  
 (a)Kiinnostusalue (b)Viivanirrotus  
 (c) Äänestysvaihe (d) Viivamalli  
 (e) Toinen reunaviiva [3]

irrotusviivoja. Viivojen keskuudessa yleisimmän suunnan määrittämisen jälkeen suoritetaan kiinnostusalueelle paloittelu, jossa alue jaetaan määritetyssä suunnassa vakioleveyisiin kaistoihin. Sitten tehdään uusi äänestys, jonka perusteena on se yleisesti toteutuva tosiseikka, että aidon rakennuksen reunan sisältävä kaista sisältää myös eniten kokonaisia irrotusviivoja. Todennäköisimmäksi äänestetyin kaistan keskiviiva otetaan rakennuksen reunaviivan alustavaksi paikaksi ja tähän algoritmin äänestysvaihe päättyy. Äänestysvaiheessa tarvittavat vakiot, äänestyssektoreiden keskuskulma ja kiinnostusalueen paloittelun kaistanleveys, määritettiin lukuisien kokeilujen perusteella arvoiksi noin 11 astetta ja kaksi pikseliä, vaikka todettiin lisäksi, että niiden suuruudet eivät vaikuta erityisen voimakkaasti algoritmin lopulliseen suorituskykyyn seuraavan vaiheen tehokkuudesta johtuen.

Äänestysvaihetta seuraa viivamallin sovitus, jossa malli määritellään itse viivasta ja sen viereisistä taustapikseleistä koostuvana. Viivamallin leveydeksi asetetaan äänestysvaiheen kaistanleveys, mutta pituutta kirjoittajat eivät mainitse, joskin pituus vaikuttaa artikkelin esimerkkien perusteella olevan kiinnostusalueen reunan pituuden luokkaa. Malli asetetaan aluksi äänestyksin määritetylle alustavalle rakennusviivalle ja se sovitetään mahdollisimman hyvin peittämiinsä viivoihin pienimmän neliösumman menetelmällä Kimin 2004 esittämään algoritmiin pohjautuen. Sovitus on valmis ja todennäköisin reunaviiva löytyy, kun ratkaisu konvergoi. Saman rakennuksen toisen reunaviivan etsintä tehdään soveltaen samaa algoritmia sillä esitiedolla, että se löytyy ensimmäisen viereiseltä äänestyskaistalta. Paloittelu tehdään nyt käyttäen jo määritettyä rakennuksen reunan suuntaa ja äänestyksessä valitaan eniten ääniä saanut määritetyn reunan kaistalle viereinen kaista.

Tähän saakka on algoritmi tyypillisesti irrottanut osoitetun rakennuksen pidemmät sivut. Lyhyempien sivujen irrottamiseen voidaan käyttää samaa algoritmia ottaen paloittelusuunnaksi määritettyä rakennuksen suuntaa vastakkainen suunta, mutta tämä on huomattavasti hankalampaa, koska lyhyemmät sivut tuottavat alkuperäisessä viivanirrotuksessa hyvin heikot vasteet, jos ollenkaan.

Kehitettyä algoritmia koekäytettiin Soulin ja Daejeonin yltä otetuilla korkearesoluutioisilla IKONOS-kuvilla vastaavasti noin 600 rakennukselle ja irrotustulokset luokiteltiin onnistumisiin, osittaisiin onnistumisiin ja epäonnistumisiin. Soulissa päädyttiin noin 71 % täydellisiin onnistumisiin ja noin 83 % jonkinasteisiin onnistumisiin. Daejeonissa vastaavat onnistumisprosentit olivat noin 69 ja 84. Erityisen hankaliksi todettiin harjakattojen harjat sekä korkeiden rakennusten seinien pystylinjat nurkkineen, jotka molemmat tulivat usein luokitelluiksi rakennusten reunoiksi. Näitä epäonnistumisia voitaisiin vähentää

korkeusmallin avulla. Jonkinasteisesti onnistuneiden reunanirrotusten tarkkuutta arvioitiin käsin kartoitettuihin reunalinjoihin verraten kulma- ja etäisyysvirheinä. Kulmavirheet olivat suoraan reunan ja vertausreunan välisiä kulmia, kun taas etäisyysvirheet laskettiin irrotetun reunan ja vertausreunan välisenä pinta-alana. Keskimääräinen kulmavirhe laski Soulissa äänestysvaiheen 3,4 asteesta viivamallin sovitusvaiheen 1,4 asteeseen ja keskimääräinen etäisyysvirhe 1,6:sta 1,2 neliöpikseliin. Daejeonissa vastaavat luvut olivat äänestysvaiheelle noin 3,8-0,9 ° ja 1,7-1,1 neliöpikseliä.

Yhteenvedossaan kirjoittajat toteavat vielä, että koko rakennuksen reunaviivojen irrottamiseksi tarvittaisiin suurempaa erotuskykyä ja että algoritmi ei toiminut pienillä, toisiaan lähellä sijaitsevilla rakennuksilla.



Kehitystyötä siis edelleen tarvitaan. Algoritmi tarjosi kuitenkin tavoitellusti vaihtoehtoisen, melko hyvin toimivan menetelmän rakennusten reunojen irrottamiseen korkearesoluutioisilta satelliittikuvilta.


### III.2. Tiet

Mokhtarzade ja Zoj (2007) ovat kehittäneet teiden tunnistusta satelliittikuvilta neuroverkkoihin perustuen. Artikkelinsa johdannoksi he toteavat kiihtyvästi kasvavan kuvadatan määrän käyvän pian mahdottomaksi analysoida, mikäli tehokkaampia menetelmiä automaattiseen piirreirrotukseen ei saada käyttöön. He kuvaavat neuroverkkotunnistusmenetelmän, jonka avulla tiepikselit saadaan tunnistettua korkean erotuskyvyn satelliittikuvilta hyvällä luotettavuudella myöhempää tielinjojen kartoittamista varten. [4]

Neuroverkot ovat neuroneista yhdisteltyjä verkkoja, joissa jokainen neuroni suorittaa syötelleen jonkin yksinkertaisen laskutoimituksen ja antaa tuloksen verkossa eteenpäin. Kytkenmät neuronien välillä voivat olla hyvin monimutkaisia, mutta tässä yhteydessä käytettiin yksinkertaisia yksikerroksisia MLP-verkkoja. Niissä neuronit on järjestetty kerroksittain siten, että neuroverkolle annetut parametrit syötetään kukin omaan neuroniinsa, joiden kautta signaalit kulkevat niin sanottuun piilokerrokseen ja lopulta ulostuloneuroneille, joita tutkimuksen neuroverkoissa oli vain yksi. Ulostuloneuronin vaste määrää tässä tapauksessa pikselin luokituksen tieksi tai taustaksi. Kirjoittajat toteavat, että neuroverkkomenetelmin päästään eroon monista tilastollisten tunnistusmenetelmien ongelmista, kuten jakaumien parametrien määrittämisestä ja jokaisen datalähteen käsittelemisestä tunnistuksessa erikseen. Tästä johtuen voitiin kehittää menetelmää, joka kävisi sellaisenaan sekä matala- että korkearesoluutioisille kuville. Neuroverkkojen toimintakykyiseksi saattaminen vaatii niiden opettamista aidon mukaista opetusdataa käyttäen, minkä seurauksena neuronien kytkenmät saavat erisuuruisia painoarvoja, joka yksilöi verkon tunnistuskyvyn. Opetuksessa oleellista on riittävän aikainen opetusiteraation lopettaminen jottei päädyttäisi epätoivottuun tilanteeseen, missä verkko on ylioppinut ja käy liiankin tarkaksi tunnistuksessaan.

Teiden tunnistukseen sopivan neuroverkon kehityksessä määritettiin aluksi 1000 opetuspikseliä Kishi-saarelta Iranista otetulta IKONOS-kuvilta, 500 tiepikseliä ja 500 taustapikseliä. Pikselit valittiin mahdollisimman kattavasti luokkansa sisältä. Delphillä ohjelmoitiin backpropagation-tyyppinen neuroverkko, joka sisälsi yhden piilokerroksen ja yhden ulostuloneuronin. Piilokerroksen neuronien määrää muutettiin kokeen kestäessä sopivimman löytämiseksi viidestä kahteenkymmeneen, mutta paljon viittä neuronia suurempien piilokerrosten todettiin kuluttavan turhaan laskentatehoa tuloksen parantumatta merkittävästi. Syöteneuronien määrä määrittyi käytettyjen parametrien lukumäärästä neljän eri lähestymistavan mukaan, jotka on esitetty seuraavissa kohdissa samoin kuin eri lähestymistavoista saadut pääpiirteiset tunnistustulokset ja neuroverkkojen havaintokuvat:

1. Syöteparametreiksi valittiin pikselin RGB-väriarvot normalisoituna välille [0,1], jolloin syöteneuroneita otettiin käyttöön kolme. Tällä neuroverkolla päädyttiin viiden piilokerrosneuronin tapauksessa 15000 opetusiteraatiokerrokseen, noin 78 %:n tiepikselien tunnistukseen, 89 %:n taustapikselien tunnistukseen ja neliöllisen keskivirheen neliöjuureen 0,25. Kaikkien pikselien oikeintunnistusprosentti laskettiin RMSE:n perusteella suoritettun kynnyksen jälkeen, ja päädyttiin 94 %:n oikeintunnistukseen.




Kuva 4: RGB-neuroverkko [4]

2. Edelliseen syötekerrokseen lisättiin neuroni, joka sai syötteekseen pikselin väriarvojen ja keskimääräisen tiepikselin väriarvojen välisen etäisyyden, joka laskettiin seuraavasti:


$$d_i = \frac{1}{441,673} \sqrt{[(R_m - R_i)^2 + (G_m - G_i)^2 + (B_m - B_i)^2]}$$

Tämän sävyetäisyyden tarkoituksena oli lisätä spektritietoa neuroverkkoon ja näin vähentää opetusiteraatioiden määrää. Tällä nelisyötoneuronisella verkolla saatiin opetusiteraatiokierrosten lukumääräksi vain 1000, tiepikseleiden ja taustapikseleiden tunnistusprosentiksi noin 71 ja 93, RMSE:ksi 0,22 ja yleiseksi tunnistusprosentiksi 94. Tiepikseleiden tunnistuksen yllättävän huononemisen epäiltiin johtuvan numeerisista ongelmista sävyetäisyyden ollessa tiepikseleille lähellä nollaa, vaikka tulokset muutoin paranivat.




Kuva 5: RGB-etäisyys-neuroverkko [4]

3. Kolmannessa lähestymistavassa kerättiin väriarvot paitsi itse kohdepikselistä, myös sen 8-naapurustosta. Näin saatiin 27-neuroninen syötekerros, jossa neuronit järjestettiin väreittäin. Tällä pyrittiin nostamaan tiepikseleiden homogeenisuuden huomioonottamista korkean erotuskyvyn tapauksessa. Laskennassa päädyttiin 3000 opetusiteraatiokierrokseen, 81 %:n tietunnistukseen, 87 %:n taustatunnistukseen, RMSE:hen 0,28 ja yleistunnistukseen 92 %. Tiepikselit tunnistettiin tähän mennessä parhaiten, mutta kaikki muut tulokset huononivat hieman verrattuna aikaisempiin lähestymistapoihin. RMSE:n nousu ja yleistunnistuksen lasku johtuivat kuitenkin osittain kokeeseen sattuneista suurista kohinapiikeistä.



Kuva 6: RGB-8-naapurusto neuroverkko [3]

4. Viimeisenä kokeena lisättiin edellisen kohdan neuroverkkoon sävyetäisyydet keskiarvosta kaikille pikseleille. Päädyttiin siis 36 neuronin syötekerrokseen. Tuloksiksi saatiin 1000 iteraatiokierrosta, noin 76 %:n tietunnistus, 94 %:n taustatunnistus, RMSE 0,20 ja 95 %:n yleistunnistus. Tietunnistusprosentti siis laski hieman, mutta tarkkuus parani paljon. Suuremman verkon todettiin lisäävän verkon laskenta-aikaa, mutta toisaalta opetuskerrosten lukumäärä putosi kolmannekseen.



Kuva 7: RGB-etäisyys-8-naapurusto neuroverkko [3]

Neuroverkon kehitystyön lopuksi verrattiin sen tuottamaa tunnistusta suurimman uskottavuuden menetelmään, jonka tietunnistus oli noin 56 %, taustatunnistus 70 %, RMSE 0,33 ja yleistunnistus 91 %. Kehitetty neuroverkko osoittautui siis merkittävästi tätä perinteistä tilastollista menetelmää paremmaksi teiden tunnistusmenetelmäksi.

Kehitettyä menetelmää kokeiltiin vielä Iranin Bushehrin satamasta otetulle QuickBird-kuvalle ja saatiin aivan IKONOS-kuvaa vastaavat tulokset. Yhteenvetona neuroverkon voitiinkin todeta suorittavan tietunnistuksen ensiluokkaisesti ja naapuripikseleiden mukaanoton nostavan tunnistusprosenttia entisestään. Todettiin lisäksi, että yli 10 neuronin piilokerrokset ovat käytännössä turhia ja että RMSE oli luotettavin parametri käytettäväksi opetusiteraatioiden lopettamiseen.

### III.3. Muutosten havaitseminen


Yksi satelliittisensoreiden historian laajimmin harjoitettuja satelliittikuvien sovellustarkoituksia on maanpinnan analysointi ja luokittelu maanpeittoluokkiin. Algoritmeja luokittelun suorittamiseen eri perusteiden on kehitetty valtaisesti, eritoten matalan erotuskyvyn kuvia varten, johtuen matalaresoluutioisten sensoreiden suuresta määrästä verrattuna uudempiin tarkkoihin sensoreihin. Suurimittakaavaisen kartoituksen näkökulmasta maanpeitto on

kuitenkin esimerkiksi edellä esitettyjä piirreirroituksia vähemmän kiinnostava menetelmä, koska jatkuvaluontoinen maanpeittokuvaus ei suurissa mittakaavoissa ole enää mielekäs esitystapa, vaan pyritään pikemminkin maanpinnan kohteiden diskreettiin kartoittamiseen. Sen sijaan maanpinnalla tapahtuneiden muutosten havaitseminen on kartoitukselle erittäin tärkeää, niin että täydennyskartoituksen tarve saadaan määritettyä nopeasti jo läpeensä kartoitetuissa maissa. Muutosten havainnointiin myös heikomman erotuskyvyn sensorit ovat aivan kelvollisia.

Aiemmin toisessa luvussa käsiteltiin Iso-Britanniassa tehtyä tutkimusta satelliittikuvien käytöstä suurimittakaavaisen kartoituksen. Koska kirjoittajat totesivat, että satelliittikuvat eivät ainakaan vielä sovellu johtavaksi aineistoksi tarkassa kartoituksessa, pyrkivät he etsimään kuville lisää vaihtoehtoisia käyttökohteita kartoitusprosessissa. Erääksi lisäarvokäyttötavaksi he määrittivät juuri täydennyskartoitusta vaativien maanpinnan muutosten havaitsemisen, koska tutkimuksen perusteella lähes kaikki kohteet kyllä havaittiin, vaikka niitä ei kyettykään tarkemmin kartoittamaan. Satelliittikuvien tehokkuuden todentamiseksi muutoshavainnoissa tehtiin vielä yksi koe, jossa Manchesterista ja Salisburystä otetuilta QuickBird-kuvilta pyrittiin määrittämään ainoastaan tapahtuneet muutokset maanpinnan peitossa. Kuvat asetettiin päällekkäin olemassaolevaan vektoriaineiston kanssa ja muutokset pyrittiin määrittämään silmämääräisesti. Havaittiin, että kaikki liikenteenjakajia ja asuntovaunuja suuremmat muutokset kyettiin havaitsemaan selvästi ja todettiin, että muutosten havaitsemisessa saatiin huomattavaa lisäarvoa verrattuna tavallisiin muutoksenhakumenetelmiin. Yksin muutoshavainnointiin käytettäväksi kaukokartoitusdatasta ei kuitenkaan ole sen kalleudesta johtuen.

Nemmour ja Chibani (2006) ovat ottaneet lähtökohdaksi maanpeiton muutosten automatisoidussa satelliittikuvamäärittämisessä tukivektorikoneet. He toteavat kaukokartoitusyhteisön huomion kiinnittyneen paljolti neuroverkkojen käyttöön niiden sujuvan monikanavakäytön vuoksi ja haluavat tukivektorinäkökulman myötä tuoda kehittyneen tilastollisen metodin käyttökelpoisuuden arvioitavaksi. [5]

Tukivektorikone on tilastollinen piirrektorimenetelmä havaintojen luokitteluun, joka on kehitetty konenäön hahmontunnistuksen saralla. Siinä pyritään maksimoimaan havaintoluokkien väliin jäävää marginaalia piirre-avaruudessa ja lineaarisesti separoitumattomien luokkien tapauksessa myöskin minimoimaan luokitteluvirheiden lukumäärää. Menetelmän keskeisin elementti ovat tukivektorit, jotka sitovat saadun ratkaisun havaintopistepöjokkoon. Esimerkiksi lineaarisesti separoituville kahdelle havaintoluokalle antaa tukivektorikone ratkaisuksi luokkarajan ja marginaalin määrittävän diskriminanttifunktion



Kuva 8: Tukivektorikone [6]

$$g(\mathbf{x}) = \sum_{i=1}^N \lambda_i y(i) \mathbf{x}^T(i) \mathbf{x} + w_0 = 0$$

missä  $\mathbf{x}(i)$  ovat koneen opetusnäytteitä,  $y(i)$  on +1 tai -1 riippuen näytteen  $x(i)$  luokasta,  $\lambda(i)$  ovat Lagrangen kertoimia ja  $w_0$  luokittelun kynnyksisarvo. Kun tukivektorikone yleistetään epälineaariseksi luokittimeksi, muodostuu sen olennaiseksi osaksi ydinfunktio, jonka tilanteenmukainen valinta on näinä päivinä kiivaan tutkimuksen kohteena. Tukivektorikoneen peruseriaatetta havainnollistaa kuva 8, jossa mustat ja valkeat pisteet kuuluvat eri luokkiin ja  $w$  on havaintojen painovektori. [6]

Nemmourin ja Chibanin kokeessa tukivektorimenetelmää käytettiin Algerian pääkaupungin Algerin laajenemisen havainnointiin pienen erotuskyvyn Landsat-monikanavakuvilta. Toukokuussa 1985 ja kesäkuussa 1996 samaan vuorokaudenaikaan otetuille kuville suoritettiin aluksi ilmakehäkoriaus ATCOR 2 -ohjelmistoa käyttäen. Seuraavaksi kuvien geometriat yhdenmukaistettiin ENVI-ohjelmiston avulla 89 pysyvistä kohteista mitatun liitospisteen perusteella. Kuvien sovituksenjälkeiseksi residuaaliksi saatiin enimmillään 0,2 pikseliä. Tämän jälkeen kuvilta valittiin 500 x 500 neliöpikselin kokoinen alue muutoshavainnointia varten ja tukivektorikone opetettiin 200 kyseisiltä alueilta käsin valitun rakenteita sisältävän pikselin opetusaineistolla. Lisäksi 400 pikseliä valittiin käytetyistä kahdesta luokasta sovellettujen sumean integroinnin ja kiinnostusvahvuuksien luotettavuusindikaattoreita varten. Luokitustestiä varten valittiin kaupungin rauna-alueilta 1000 ja muulta kovalta 1300 testiluokkiin kuuluvaa pikseliä. Itse kokeessa kokeiltiin eri ydinfunktioita parhaan luokittelutuloksen saavuttamiseksi ja tuloksia verrattiin neuroverkkojen antamiin. Yleisesti todettiin, että tukivektorikoneet tuottavat neuroverkkoja tarkempia luokittelutuloksia ja että parhaat tulokset saavutettiin käyttäen ydinfunktiona kuudennen

asteen globaalia polynomia (noin 98 %:n oikein-luokittelu, neuroverkoilla 94 %), vaikka pienimmän solmumäärän RBF-ydinfunktiolla päästiinkin lähes samoihin tuloksiin. Menetelmää kehitettiin edelleen yhdistämällä useita eri tukivektorikoneita käyttäen yhdistysmenetelmänä sumeaa integrointia sekä kiinnostavuusvahvuuksia, jolloin päädyttiin parhaimmillaan noin 99 %:n luokittelu-tarkkuuteen. Tällöin myös muutosten havainnoinnin voi todeta olevan menetelmällä varsin luotettavaa ja aiheellisesti tarkempaan kartoitukseen ohjaavaa.

## IV Yhteenveto

Tässä seminaarityössä tarkasteltiin korkean erotuskyvyn satelliittikuvien sopivuutta suurten mittakaavojen kartoituskäyttöön viiden aihetta käsittelevän artikkelin myötä. Iso-Britanniassa tehdyssä tutkimuksessa oli tarkasteltu 60 cm:n erotuskyvyn QuickBird-satelliittikuvien käyttömahdollisuuksia kansallisen karttalaitoksen topografisessa kartantuotantoprosessissa. Tuloksena oli saatu, että näinkään tarkat satelliittikuvat eivät sovellu johtavana aineistona vaaditun tarkkuusluokan kartoitukseen, koska kuvausohjeiden mukaista kohteiden määrittystä ei kyetä suorittamaan kattavasti. Erityisen hankaliksi havaittiin hyvin kapeat viivamaiset kohteet. Sen sijaan kyseenomaiset satelliittikuvat sopivat mainiosti toissijaiseksi kartoituslähteeksi ja maanpinnalla tapahtuneiden täydennyskartoitusta vaativien kohteiden havaitsemiseen. Toinen tutkimus esitteli korkean erotuskyvyn satelliittikuvakolmikön käyttöä korkeustiedon kartoituksessa. Siinä kuvakolmikkoa oli käsitelty stereokuvapareittain, joilta korkeuskartoitusta tehtiin stereokartoituksen tapaan eteenpäinleikkauksin ja lopulta laskettu tieto yhdistettiin siten, että epäluotettaviksi todetut liitospisteet pudotettiin pois laskennasta. Kolmikuvakartoituksena saadut korkeudet todettiin aidon vertauskorkeusmallin myötä stereokartoituksen tuottamia tarkemmiksi lähes kaikissa tapauksissa. Menetelmän eduksi todettiin myös sen vankkuus ja luotettava toiminta jopa, kun pilvet peittivät kuvilta suuria alueita.

Automaattisia kartoitusmenetelmiä satelliittikuvilta käsiteltiin kolmen artikkelin kautta. Niistä ensimmäinen käsitteli rakennusten reunaviivojen puoliautomaattista irrottamista. Kehitetty irrotusalgoritmi operoi valmiiksi irrotetuille viivoille äänestysmenettelyä ja viivamallin pienimmän neliösumman sovitusta käyttäen. Menetelmän oli todettu irrottavan rakennusten pitkien sivujen reunat IKONOS-kuvilta oikein keskimäärin noin 84 prosentin luotettavuudella irrotettujen reunojen suuntatarkkuuden oltua keskimäärin 1,3 astetta. Lyhyempien sivujen reunojen irrottaminen oli todettu lähes mahdottomaksi ja lisäkehitystä sekä tarkempia kuvia kaivattiin. Toinen esitelty irrotusalgoritmi kehitti MLP-neuroverkkomenetelmää teiden irrottamiseksi. Neuroverkolle oli etsitty sopivia syöteparametreja, optimaalista piilokerroksen neuronien lukumäärää ja sopivaa verkon opetusiteraation lopetusehtoa. Aineistona oli käytetty IKONOS-kuvia ja parhaaksi syöteparametrien yhdistelmäksi oli määritetty RGB-8-naapurusto-etàisyys -yhdistelmä. Sopivimmaksi piiloverkon neuronien määräksi oli saatu maksimissaan 15. Optimaaliseksi todetulla verkkorakenteella saatiin tie- ja yleistunnistusprosentit 76 ja 95 sekä tunnistustarkkuus RMSE 0,20. Nämä arvot todettiin jopa kymmeniä prosenttiyksiköitä suurimman uskottavuuden menetelmän antamia paremmiksi. Kolmantena kartoitusautomaation artikkelina käsiteltiin tukivektorikonemenetelmän maanpeiton muutosten havainnointiin esittelevä tutkimusraportti. Tutkimuksessa oli selvitetty muun muassa menetelmälle sopivien ydinfunktioiden muotoa. Tukivektorikone opetettiin kahdelta yli kymmenen vuoden välein otetulta Landsat-monikanavakuvalta valittujen 200 rakennetun maan opetuspikselin voimin. Kaikista kokeilluista menettelytavoista antoi paras, monia tukivektorikoneita yhdistänyt menetelmä, luokittelutarkkuuden 99 %.

Luettujen artikkelien pohjalta on helppo todeta, että suurimittakaavainen satelliittikuvakartoitus elää vahvasti tulemisensa aikaa ja satelliittikuvien käyttö operatiivisissa kartoitusyhteyksissä voi toteutua, mikäli korkearesoluutioisia kuvausinstrumenttejä saadaan käyttöön lisää kuvien hintojen laskemiseksi. Satelliittikuvadatan määrä kasvaa kuitenkin jatkuvasti kiihtyvää vauhtia, joten uusia, tehokkaampia ja entistä automaattisempia menetelmiä on löydettävä tulevan aineiston analysoimiseksi. Sellaiset tuoret menetelmät kuten neuroverkot ja tukivektorikoneet ovat jo saaneet oikeutuksensa tarkassa kartoituksessa ja niiden kehitys käy kuumana. Kynnyskysymyksenä tarkkaan kartoitukseen on ennen kaikkea kuvien erotuskyvyn parantuminen selvästi alle puolen metrin mittaluokkaan. Erotuskykyvaatimuksen toteutuessa avautuu valtava sovelluskenttä kehityspotentiaaleineen, ja kolmikuvakartoitus on vain yksi hyvä esimerkki uusista tekniikoista vankempaan ja tarkempaan kartoitukseen.

## **Lähteet**

- [1] D.A. Holland, D.S. Boyd, P. Marshall: Updating topographic mapping in Great Britain using imagery from high-resolution satellite sensors, *ISPRS Journal of Photogrammetry & Remote Sensing*, vol. 60, May 2006, ss. 212-223
- [2] Hannes Raggam: Surface Mapping Using Image Triplets: Case Studies and Benefit Assessment in Comparison to Stereo Image Processing, *Photogrammetric Engineering & Remote Sensing*, vol. 72, May 2006, ss. 551-563
- [3] Taejung Kim, Tae-Yoon Lee, Kyung-Ok Kim: Semiautomatic Building Line Extraction from Ikonos Images Through Monoscopic Line Analysis, *Photogrammetric Engineering & Remote Sensing*, vol. 72, May 2006, ss. 541-549
- [4] M. Mokhtarzade, M.J. Valadan Zoj: Road detection from high-resolution satellite images using artificial neural networks, *International Journal of Applied Earth Observation and Geoinformation*, vol. 9, January 2007, ss. 32-40
- [5] Hassiba Nemmour, Youcef Chibani: Multiple support vector machines for land cover change detection: An application for mapping urban extensions, *ISPRS Journal of Photogrammetry & Remote Sensing*, vol. 61, November 2006, ss. 125-133

## **Viite**

V. Tao, K. Jacobsen, J. Jensen, G. Sohn: Foreword - Mapping from High-resolution Satellite Imagery, *Photogrammetric Engineering & Remote sensing*, vol. 72, May 2006, ss. 529-530