

Hyperspektrikuvaus kaukokartoitusmenetelmänä

Elmeri Viuho

790351A

LuK-seminaari ja -tutkielma

Maantieteen tutkinto-ohjelma

Oulun yliopisto

2.2.2021

Tiivistelmä

Hyperspektrikuvauksen käyttö kaukokartoitusmenetelmänä on lisääntynyt merkittävästi viimeisten kahden vuosikymmenen aikana. Tärkein tekijä, joka erottaa hyperspektrikuvauksen muista kaukokartoitusmenetelmistä on sen korkea spektrinen resoluutio. Hyperspektrisensori kykenee samanaikaisesti mittaamaan säteilyä jopa sadoilla hyvin kapeilla aallonpituuskanavilla, joiden perusteella voidaan muodostaa kuvattavan kohteen ominaisspektri. Kaukokartoituskäytössä hyperspektrisensorit on asennettu ilmassa tai kiertoradalla toimivaan alustaan, ja keräävät kuvattavasta kohteesta dataa, jolla on sekä alueelliset että spektrinen ulottuvuus. Huomionarvoista menetelmässä on myös sen keräämä valtava datamäärä, joka voi olla kymmen- tai satakertainen muihin kuvausmenetelmiin verrattuna johtuen aallonpituuskanavien määrästä.

Käytännön sovelluksia hyperspektrikuvaukselle löytyy useilta eri tieteenaloilta. Korkea spektrinen resoluutio mahdollistaa usein tiettyjen kemiallisten yhdisteiden olemassaolon ja määrän havainnoinnin, jonka perusteella voidaan tehdä johtopäätöksiä kuvattavasta kohteesta. Sovelluksia on kehitetty etenkin ympäristöntutkimuksen sekä maa- ja metsätalouden tarpeisiin, mutta monet näistä menetelmistä ovat vielä kehitysvaiheessa. Pisimmälle kehittyneitä ovat maa- ja metsätaloudessa käytettävät menetelmät, joiden avulla voidaan kerätä hyvin tarkkaa tietoa kasvien tilasta, ja havaita jo varhain erilaisia stressitekijöitä tuholaisista ravinteiden puutteeseen. Monet näistä menetelmistä ovat myös sovellettavissa ympäristöntutkimukseen, minkä lisäksi löytyy pitkä liuta erilaisia metodeja esimerkiksi vedenlaadun ja indikaattorimineraalien havaitsemiseen.

Valtavasta potentiaalista huolimatta hyperspektrikuvauksen laaja-alaiseen tutkimuskäyttöön liittyy myös ongelmia. Korkean spektrisen resoluution hinta on menetelmän huomattava monimutkaisuus ja suhteellisen korkea häiriöalttius. Hyperspektrikuvauksen onnistunut käyttö vaatii tutkijalta usein varsin pitkälle menevää erikoistumista, eikä vankka osaaminenkaan aina takaa onnistunutta lopputulosta. Kenttätutkimuksessa vaihtelevat valaistusolosuhteet ja jatkuvasti muuttuva ilmakehän tila haittaavat hyperspektrikuvien toistettavuutta, joissain tapauksissa jopa hyvin merkittävästi.

Sisältö

1 Johdanto	4
2 Teoria	5
2.1 Kaukokartoitus	5
2.2 Sähkömagneettinen säteily	7
3 Menetelmä ja teknologia	11
3.1 Hyperspektrikuvaus menetelmänä	11
3.2 Sensorit ja alustat	13
4 Sovellukset	15
4.1 Kasvillisuuden kartoittaminen	16
4.2 Muut sovelluskohteet	18
5 Pohdinta	21
5.1 Rajoitukset	21
5.2 Tulevaisuus	22
6 Kirjallisuutta	24

1 Johdanto

Kaukokartoitusta on tehty vuosikymmenten ajan erilaisilla menetelmillä. Perinteisistä kameroista on siirrytty satelliittien multispektrisensoreihin ja muihin kehittyneempiin ja erikoistuneempiin kuvantamismenetelmiin. Eräs viime aikojen merkittävimpiä kehitysaskeleita on ollut entistä parempien hyperspektrikameroiden ja niitä hyödyntävien kartoitusmenetelmien kehittyminen. Hyperspektrikuvauksen suurin vetonaula on sen huomattavan tarkka spektrinen resoluutio. Jo vanhempien multispektrikameroiden kanssa on voitu analysoida tiettyjä kohteita niiden poikkeavien heijastusominaisuuksien kautta, mutta hyperspektrisensoreiden hyödyntäminen vie tämän tarkastelun aivan uudelle tasolle.

Perinteisessä värillisessä digitaalisessa valokuvassa on kolme kanavaa, joille sensori tallentaa mitattavansa sähkömagneettisen säteilyn arvoja. Satelliittikuvissa, jotka on tyypillisesti otettu multispektrikameroilla, on yleensä neljästä seitsemään kanavaa. Hyperspektrikuvaus nostaa kanavien määrän jopa useaan sataan, minkä lisäksi kanavat ovat aallonpituusalueeltaan kapeita ja lähes jatkuvia (Manolakis ym. 2016: 8). Tämä erottelukyky mahdollistaa tarkkuuden, jota ei ole ennen voitu saavuttaa.

Etenkin 2000-luvulla on tehty huomattava määrä tutkimusta liittyen hyperspektrikuvauksen mahdollisiin sovelluskohteisiin. Varsinkin maa- ja metsätalouden, geologian ja ympäristöntutkimuksen aloita onkin löytynyt runsaasti käyttöä tarkalle kaukokartoitusmenetelmälle. Suoraan menetelmällä on pystytty havainnoimaan erilaisten kemiallisten komponenttien, kuten esimerkiksi klorofyllin ja tiettyjen mineraalien, olemassaoloa ja määrää kartoitettavassa kohteessa, ja näitä puolestaan on onnistuneesti käytetty indikaattoreina muista ilmiöistä, kuten biodiversiteetistä (Saarinen ym. 2018; Gholizadeh ym. 2020) tai kultamalmin läsnäolosta kuvausalueella (Ferrier & Wadge 1996). Lisäksi varsinkin 2010-luvulla hyperspektrikuvausta soveltava tutkimus on usein linkittynyt erilaisten miehittämättömien ilma-alusten hyödyntämiseen kaukokartoitusalueina.

Tässä työssä tarkastellaan paitsi hyperspektrikuvauksen peruskäsitteistöä ja menetelmiä, myös paneudutaan etenkin menetelmän soveltamiseen erilaisissa ympäristöntutkimuksen kohteissa. Tarkoituksena on esitellä monipuolisesti menetelmän käyttökohteita ja selvittää, mitä mahdollisuuksia ja haasteita hyperspektrikuvauksen käyttöön tutkimuksessa liittyy. Työn tavoitteena on esitellä menetelmää ja sen soveltamista lukijalle ja tarjota perusta omaa tarkempaa perehtymistä varten.

2 Teoria

2.1 Kaukokartoitus

Yksinkertaisimmillaan määriteltynä kaukokartoitus on tiedon keräämistä mistä tahansa kohteesta siten, että mittalaite ei ole suorassa kontaktissa mitattavan kohteen kanssa (Lillesand ym. 2015: 1). Luonnollisesti tällainen määritelmä on varsin laava ja kattaa kaikkennäköisiä menetelmiä maan magneettikentän mittaamisesta ruumiinlämmön mittaamiseen infrapunalämpömittarilla. Tässä työssä olemme kuitenkin kiinnostuneita kaukokartoituksesta spatiaalisen tiedon näkökulmasta, joten tarvitsemme kapeamman määritelmän. Tämän työn kontekstissa kaukokartoituksella tarkoitetaan tiedon keräämistä maanpinnasta ja sen ilmiöistä mittaamalla sähkömagneettisen säteilyn määrää ilmassa tai kiertoradalla olevilla sensoreilla (Campbell 2002: 6).

Kaukokartoittamalla voidaan kohteesta kerätä tietoa kolmella eri tavalla. Kaikkein yleisin menetelmä on kohteesta heijastuneen säteilyn mittaaminen. Kaikki kohteet heijastavat jossain määrin säteilyä, ja tämä tapa perustuu ulkopuolisesta säteilylähteestä, yleensä aurinko, peräisin olevan heijastuneen säteilyn mittaamiseen. Toinen tapa on mitata kohteen itsensä lähettämää säteilyä, mikä yleensä tarkoittaa lämpösäteilyn mittaamista. Kolmannessa tavassa mitataan myös kohteesta heijastunutta säteilyä, mutta tällä kertaa säteily ei ole peräisin ulkoisesta lähteestä, vaan mittalaitteen itsensä tuottamaa (Campbell 2002: 46). Hyperspektrikuvauksen tapauksessa kaukokartoitus tapahtuu pääosin ensimmäisen tavan mukaisesti heijastuneen säteilyn mittaamisena, mutta infrapuna-alueella on mahdollista tarkastella myös kohteen itsensä emittoimaa säteilyä.

Kaukokartoittamalla kerätyn kuva-aineiston tärkeimpiä ominaisuuksia on sen resoluutio. Resoluutiolla tarkoitetaan kuvien erottelukykyä ja se voidaan jakaa karkeasti neljään päätyyppiin: spatiaaliseen, spektriseen, radiometriseen ja temporaaliseen resoluutioon (Lillesand ym. 2015: 72). Näistä helpoiten ymmärrettävä on spatiaalinen resoluutio, joka käytännössä tarkoittaa pienintä kohdetta, joka voidaan erottaa kuvista (Dodge & Congalton 2013: 5). Digitaalisten kuvien tapauksessa spatiaalista resoluutiota rajoittaa mittalaitteen kennon koko, ja sitä kautta kuvan pikseleiden määrä. Yksinkertaisimmillaan spatiaalinen resoluutio voidaan ymmärtää yksittäiseen pikseliin mahtuvan alueen kokona, joka riippuvaista paitsi mittalaitteen erottelukyvystä myös mittausetäisyydestä (Campbell 2002: 16).

Spektrinen resoluutio tarkoittaa mittalaitteen kykyä erotella kohteita niiden erilaisen spektriominaisuuksien perusteella (Lillesand ym. 2015: 73). Spektristä resoluutiota määrittävät sensorin kyky erotella mitattavaa säteilyä eri aallonpituuskanaville, sekä näiden kanavien määrä, leveys ja sijainti spektrissä (Dodge & Congalton 2013: 7). Esimerkiksi perinteisessä mustavalkokuvassa on yksi leveä kanava näkyvän valon alueella, ja mustavalkokameran kenno reagoi vain heijastuneen valon määrään rippumatta sen tarkemmasta aallonpituudesta. Värillisessä valokuvassa puolestaan on kolme leveää kanaavaa, jotka kattavat punaisen, sinisen ja vihreän valon aallonpituusalueet (Lillesand ym. 2015: 33, 68). Spektrinen resoluutio on erityisen tärkeässä roolissa hyperspektrikuvauksen tapauksessa, koska sen pääominaisuuksia on kohteiden erottelu niiden ominaisspektrien perusteella.

Radiometrinen resoluutio on myös käytettävän sensorin ominaisuus ja tarkoittaa käytännössä sensorin kykyä havaita eroja eri kohteiden kirkkaudessa (Lillesand ym. 2015: 73). Esimerkiksi Landsat-satelliiteista löytyvä 8-bittinen Thematic Mapper -sensori kykenee tallentamaan kultakin aallonpituuskanavalta jokaiselle pikselille intensiteetin, jolle annetaan numeerinen arvo väliltä 0–255 (Dodge & Congalton 2013: 8). Korkeampi radiometrinen resoluutio tarkoittaa, että sensori voi jakaa arvoja laajemmalla numeerisella skaalalla, ja siten paremmin erotella kohteita myös tilanteessa, jossa niiden välinen kontrasti ei ole suuri.

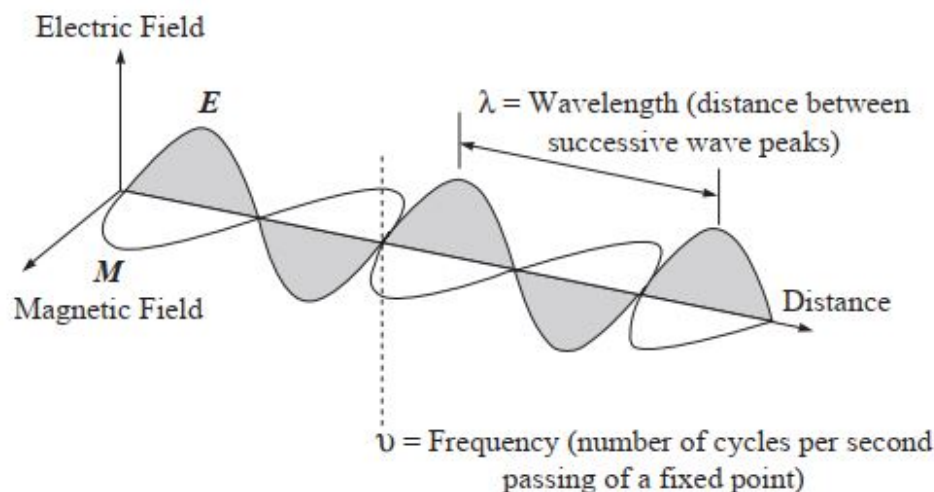
Viimeinen resoluution muoto on temporaalinen eli ajallinen resoluutio. Temporaalinen resoluutio tarkoittaa kykyä erottaa ajan suhteen tapahtuvia muutoksia, eli käytännössä, kuinka usein mittaus voidaan toistaa, ja kuinka tiheä aikasarja mittauksista voidaan muodostaa (Dodge & Congalton 2013: 5). Ajallisen resoluution tarve riippuu merkittävästi tutkittavasta kohteesta tai ilmiöstä. Lentokoneilla ja lennokeilla tapahtuva kartoitus voidaan usein toteuttaa niin tiheästi kuin halutaan, mutta satelliittikuvien tapauksessa ajalliseen resoluutioon vaikuttavat merkittävästi satelliittien kiinteät kiitoradat (Lillesand ym. 2015: 73).

Kaukokartoitus itsessään on vain tiedonkeruumenetelmä, ja kaukokartoittamalla tuotettu tieto on arvotonta ilman tarkempaa tulkintaa ja analysointia. Kaukokartoitus voidaan nähdä myös osana laajempaa prosessia, jossa tietoa paitsi kerätään, myös muokataan ja sovelletaan yhdessä muiden tiedonlähteiden kanssa (Campbell 2002: 10–15). Tämän prosessin lähtökohtana on tutkittavien fyysikaalisten ilmiöiden tuntemus, jo-

ka löytyy erikoistuneiden tieteenalojen, kuten geologian ja maantieteen alta. Sensoreiden keräämää tietoa täytyy osata tulkita ja siitä erottaa kulloisenkin tutkimuksen kannalta olennainen aines. Vasta tätä karsittua ja analysoitua tietoa voidaan käyttää yhdessä muiden tiedonlähteiden kanssa erilaisten sovellusten toteuttamiseen.

2.2 Sähkömagneettinen säteily

Sähkömagneettista säteilyä on kaikkialla ympärillämme: auringon valo, nuotiosta säteilevä lämpö ja matkapuhelinverkkojen viestiliikenne ovat kaikki perusuonteeltaan samanlaista sähkömagneettista säteilyä. Sähkömagneettinen säteily on energiaa, joka käyttäytyy aaltoteorian mukaisesti, ja muodostuu muuttuvasta sähkö- ja magneettikentästä, jotka ovat kohtisuorassa toisiinsa ja kulkusuuntaan nähden (Lillesand ym. 2015: 4). Säteily etenee tyhjiössä vakionopeudella c , ja on muodoltaan siniaaltomainen (Kuva 1). Sähkömagneettista säteilyä syntyy monien erilaisten prosessien, kuten muun muassa atomien lämpöliikkeen, radioaktiivisen hajoamisen ja elektronien energiatasojen muutosten seurauksena (Campbell 2002: 25).




Kuva 1: Sähkömagneettinen säteily (Manolakis ym. 2016)

Sähkömagneettisella säteilyllä on kolme perusominaisuutta: aallonpituus, taajuus ja amplitudi. Aallonpituus on kahden aallonhuipun välinen etäisyys, ja sitä voidaan mitata normaaleilla pituuden yksiköillä. Taajuus on tietyn pisteen ohittavien aaltojen määrä aikayksikössä, ja sitä mitataan Hertzeinä. Amplitudi puolestaan kuvaa kunkin aallonhuipun korkeutta, ja aallon kuljettama energia on verrannollinen amplitudin neliöön (Camp-

bell 2002: 26). Sähkömagneettinen aalto noudattaa aaltoliikkeen perusyhtälöä, joten aallonpituus ja taajuus ovat kääntäen verrannolliset toisiinsa, ja kumpaa tahansa voitaisiin käyttää aallon kuvaamiseen. Kaukokartoituksen kontekstissa sähkömagneettiset aallot kuitenkin tyypillisesti luokitellaan aallonpituuksien mukaan (Lillesand ym. 2015: 4).

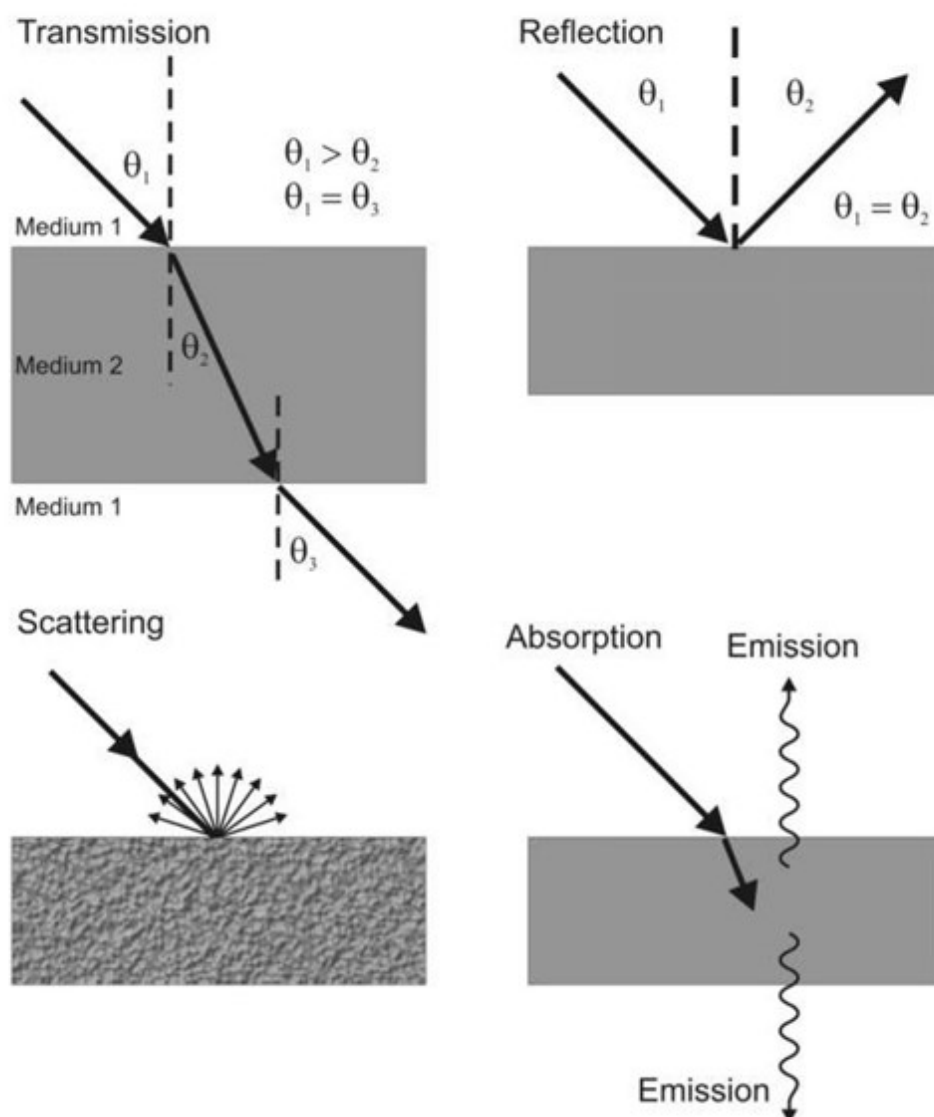
Sähkömagneettisen säteilyn aallonpituus ja taajuus ovat luonteeltaan jatkuvia, ja voivat siten saada minkä tahansa arvon ja muodostavat sähkömagneettisen spektrin (Kuva 2). Sähkömagneettinen spektri jaetaan tyypillisesti erilaisiin aallonpituusalueisiin, joskin nämä alueet ovat täysin keinotekoisia, eikä varsinaisesta spektristä jatkuvuutensa vuoksi löydy selvärajaisia jakolinjoja (Campbell 2002: 28). Kaukokartoituksessa käytetään pääsääntöisesti aallonpituusalueita ultraviolettisäteilystä lyhytaaltoiseen mikroaaltosäteilyyn, mutta hyperspektrikuvauksen tapauksessa tyypillisesti käytössä ovat vain näkyvän valon ja infrapunasäteilyn alueet (Lillesand ym. 2015: 271).



Kuva 2: Sähkömagneettinen spektri (Borengasser ym. 2008)

Kaukokartoituksessa sähkömagneettinen säteily, oli se sitten peräsin auringosta tai mittalaitteesta, kulkee ennen mittaustulosta kahdesti ilmakehän läpi ja heijastuu kuvattavasta kohteesta vuorovaikuttaen sekä ilmakehän, että fyysisen kohteen kanssa (Campbell 2002: 32, 41). Kaukokartoituksen kannalta näistä vuorovaikutustavoista neljä on erityisen tärkeitä: sironta, absorboituminen, heijastuminen ja transmissio (Kuva 3).

Sirontaa tapahtuu, kun sähkömagneettinen säteily etenee ilmakehän läpi ja vuorovaikuttaa ilmakehässä olevien hiukkasten kanssa. Sironnassa etenevä aalto muuttaa suuntaansa vuorovaikutuksen seurauksena, ja suunnan muutoksen suuruus riippuu hiukkasten koosta, määrästä ja säteilyn aallonpituudesta. Lisäksi luonnollisesti myös ilmakehän läpi



Kuva 3: Sähkömagneettisen säteilyn vuorovaikutus pinnoissa (Borengasser ym. 2008)

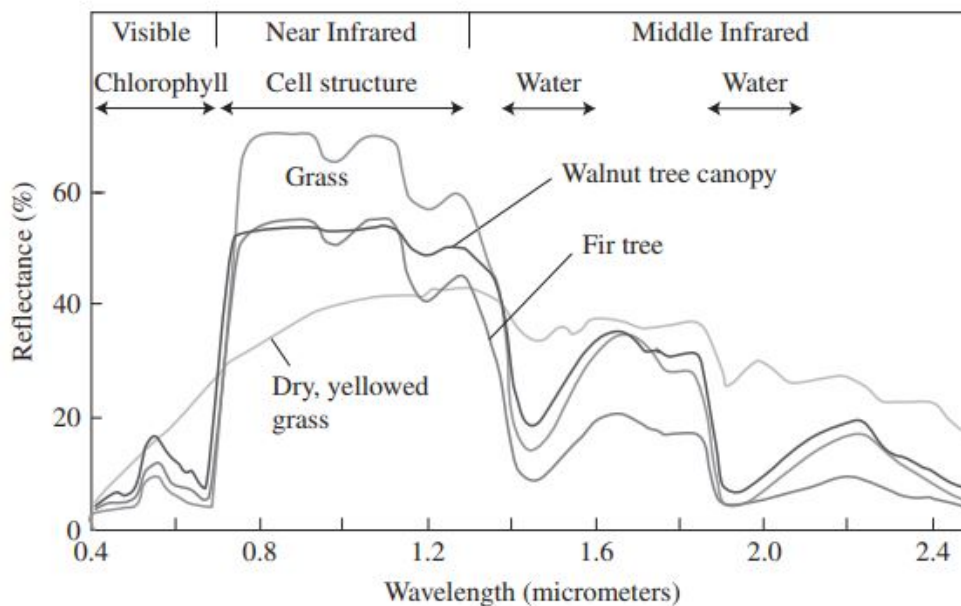
kuljettu matka vaikuttaa sironnan määrään (Manolakis ym. 2016: 84). Kaukokartoituksen kannalta erityisen olennaista on niin sanottu Rayleigh-sironta, joka aiheutuu hiukkasista, jotka ovat kooltaan huomattavasti säteilyn aallonpituutta pienempiä, kuten ilmakehän molekyyleistä. Rayleigh-sironnan suuruus kasvaa käänteisesti suhteessa aallonpituuteen, eli sen seuraukset ovat merkittävimmät lyhyillä aallonpituuksilla. Muun muassa sininen taivas johtuu sinisen aallonpituuden voimakkaasta sironnasta (Lillesand ym. 2015: 9). Voimakas Rayleigh-sironta estää useimmissa tapauksissa ultraviolettisäteilyn käytön kaukokartoitus tarkoituksessa, sillä voimakkaan sironnan takia mittaus kertoisi enemmän ilmakehän tilasta kuin mitattavasta kohteesta (Campbell 2002: 35).

Absorboitumisessa osa sähkömagneettisen säteilyn energiasta muuttuu väliaineen sisäenergiaksi. Absorboitumista tapahtuu niin ilmakehässä kuin myös maanpinnalla olevissa kohteissa, ja se voimakkaasti riippuvaista säteilyn aallonpituusalueesta (Lillesand ym. 2015: 10). Ilmakehän kaasujen, etenkin hapen, hiilidioksidin ja vesihöyryn, absorptioita takia vain tietyt aallonpituudet pääsevät maan pinnalle asti, ja muodostavat niin sanottuja säteilyikkunoita. Säteilyikkunoiden olemassaolo on erityisen tärkeää kaukokartoituksen kannalta, sillä ne määrittävät ne aallonpituusalueet, joilta kuvia voidaan muodostaa (Campbell 2002: 38).

Kohdatessaan läpinäkymättömän pinnan, sähkömagneettinen säteily heijastuu, eli muuttaa suuntaansa. Heijastavan pinnan epäsäännöllisyydet vaikuttavat heijastuksen luonteeseen. Mikäli epäsäännöllisyydet ovat pieniä suhteessa säteilyn aallonpituuteen, tapahtuu peilimäinen heijastuminen ja kaikki tai lähes kaikki säteily heijastuu samaan suuntaan. Jos epäsäännöllisyydet puolestaan ovat suuria suhteessa aallonpituuteen, on heijastuminen diffuusia, ja säteily siroaa kaikkiin suuntiin. Käytännössä kumpikaan heijastumistapa ei koskaan tapahdu puhtaassa muodossa, vaan rajapinnoissa tapahtuu aina jonkin verran sirontaa, joka ei kuitenkaan koskaan jakaudu aivan tasaisesti kaikkiin suuntiin (Campbell 2002: 41-42).

Sähkömagneettinen säteily voi myös kulkea väliaineen läpi ilman merkittäviä voimakkuuden tai suunnan muutoksia. Tällöin kyseessä on transmissio, jonka voimakkuutta kuvaa väliaineen läpäisykyky. Läpäisykykyyn vaikuttaa paitsi itse väliaine, myös sen paksuus, ja se on riippuvaista myös säteilyn aallonpituudesta (Campbell 2002: 43).

Kohdatessaan maanpinnan kohteen sähkömagneettinen säteily kokonaisuudessaan absorboituu, heijastuu tai läpäisee kohteen. Kaikki nämä vuorovaikutukset eivät kuitenkaan tapahdu samassa suhteessa, vaan ovat riippuvaisia kohteen materiaalista ja säteilyn aallonpituudesta. Koska eri aallonpituudet käyttäytyvät eri tavalla, voidaan tämän ilmiö avulla tunnistaa eri materiaaleja (Manolakis ym. 2016: 6). Kaukokartoitus tapahtuu useimmiten heijastuneen säteilyn perusteella, joskin heijastuneesta säteilystä puuttuvat aallonpituudet kertovat myös kohteen absorptiopiirteistä. Laskemalla heijastuneen ja saapuneen energian välinen suhde saadaan kullekin materiaalille ja aallonpituudelle tyypillinen heijastusuhde, joka kertoo, kuinka suuri osa kyseisellä aallonpituudella saapuvasta säteilystä heijastuu kohteesta. Määrittämällä heijastussuhde jatkuvana kaikille aallonpituuksille saadaan materiaalille määritettyä sen ominaisspektri (Lillesand ym. 2015: 13).



Kuva 4: Esimerkki erilaisten kasvinosien ominaisspektreistä (Manolakis ym. 2016)

Esimerkin ominaisspektrien muodostumisesta näemme kuvassa 4. Kuvaaajan x-akselilla on sähkömagneettisen säteilyn aallonpituus ja y-akselilla heijastuneen säteilyn prosentuaalinen osuus. Kun heijastussuhde piirretään jatkuvana koko halutulle aallonpituusalueella, saadaan näkyviin kohteen ominaisspektri. Kuvasta voidaan havaita myös yhteyttäviä kasvinosien yhteisiä spektriipiirteitä, kuten sinisen ja punaisen valon voimakas absorboituminen ja lähi-infrapunasäteilyn vahva heijastuminen.

3 Menetelmä ja teknologia

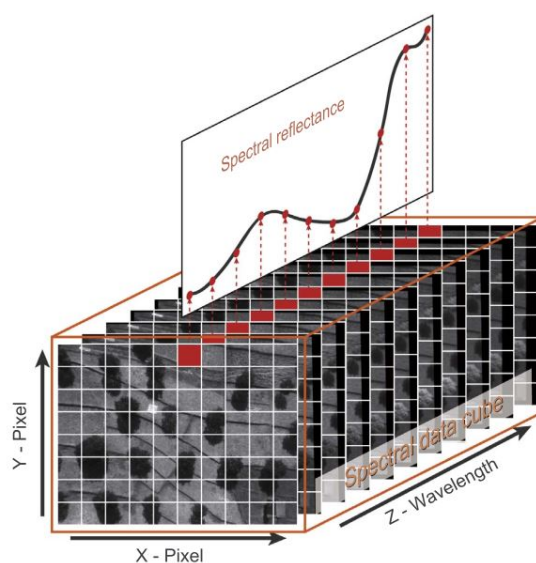
3.1 Hyperspektrikuvaus menetelmänä

Ominaisuus, joka erottaa hyperspektrikuvausmuista kaukokartoitusmenetelmistä on sen toistaiseksi lyömätön spektrinen resoluutio. Hyperspektrisenä kerää saman aikaisesti digitaalisia kuvia useilta hyvin kapeilta ja lähes jatkuvilta aallonpituuskanavilta (Manolakis ym. 2016: 8). Moderni hyperspektrikamera voi kerätä dataa yli kahdeltasadalta kanavalta, ja spektrinen resoluutio voi parhaimmillaan olla jopa alle kymmenen nanometriä (Lillesand ym. 2015: 271). Tyypillisesti sensorit toimivat näkyvän valon ja infrapunasäteilyn aallonpituusalueilla yltäen aina pitkäaaltoiseen lämpösäteilyyn asti (Lillesand ym. 2015: 271). Hyperspektrikuvauskeinoin voidaan tietoa kerätä niin hyvällä tark-

kuudella, että kuvauksen perusteella voidaan muodostaa kohteelle ominainen heijastus- tai emissiospektri. Korkean spektrisen resoluution ansiosta hyperspektrikuvia analysoidessa voidaan hyödyntää spektroskopian tieteenalan menetelmiä, mikä mahdollistaa muun muassa tarkan materiaalien tunnistamisen ja ilmakehän vaikutusten arvioinnin pelkästään kuvan itsensä sisältämän tiedon avulla (Campbell 2002: 407).

Vaikka hyperspektrikuvauksella voidaan muodostaa suhteellisen tarkka kuva kohteen ominaisspektristä, on tunnistusta mahdoton tehdä vain sen avulla. Jotta mitattua spektriä voidaan mielekkäästi tulkita, on sitä verrattava johonkin. Tässä kohtaa kuvaan astuvat niin kutsutut spektrikirjastot, joihin on tallennettu valtavat määrät dataa erilaisista kenttä- ja laboratoriomittauksista, niiden olosuhteista ja käytetystä sensoreista (Campbell 2002: 410). Spektrikirjastot ovat pääosin julkisesti saatavilla ja sisällytettynä moniin kuvankäsittelyohjelmiin. Vasta vertailemalla mitattua spektriä kirjastojen sisältöön, voidaan kohteita tunnistaa luotettavasti (Borengasser ym. 2008: 58).

Hyperspektrikuvausta käytetään laajasti tähtitieteessä ja laboratorionäytteiden analysoinnissa, mutta poiketen näistä käyttökohteista, kaukokartoituksessa ei tarkastella pistemäisiä kohteita. Tarkasteltavat kohteet ovat alueita maan pinnalla, joten niillä on spektriulottuvuuden lisäksi kaksi spatiaalista ulottuvuutta (Campbell 2002: 408). Hyperspektriaineistoa kuvataan usein niin sanottuna datakuutiona (Kuva 5), jonka x- ja y-akseleilla on kaksi spatiaalista ulottuvuutta tavallisen ilmakuvan tapaan, ja z-akselilla mitatun säteilyn aallonpituus (Manolakis ym. 2016: 9).



Kuva 5: Hyperspektridata kolmiulotteisena tietorakenteena (Ishida ym. 2018)

Spatiaalisten ulottuvuuksien takia hyperspektrikuvauksen käyttöön kaukokartoituksessa liittyy tiettyjä ongelmia, joita ei pistemäisiä kohteita tarkasteltaessa ole. Näistä ongelmista merkittävin on spektrien sekoittuminen. Sensorin kennossa on vain rajallinen määrä pikseleitä, eikä pikselin vastaanottama säteily ole useimmiten peräisin yhdestä yhtenäisestä kohteesta (Campbell 2002: 412). Eri kohteiden säteily voi sekoittua joko lineaarisesti tai epälineaarisesti riippuen siitä tapahtuuko sekoittuminen säteilyn osuessa sensoriin vai ennen sitä. Lineaarista sekoittumista tapahtuu, kun kohteen optisesti poikkeavat alueet ovat suhteellisen suurikokoisia, ja kukin fotoni heijastuu vain kerran ennen sensoriin osumista. Sekoittuminen on epälineaarista, kun poikkeavat kohteet ovat pienikokoisia, esimerkiksi maaperän mineraalirakeita, ja fotoni heijastuu useammasta kuin yhdestä materiaalista (Manolakis ym. 2016: 443).

Spektrien sekoittumiseen liittyviä ongelmia voidaan ratkoa analysoimalla sensorin mittaamaa sekoittunutta spektriä. Analyysi pyrkii erottamaan sekoituksesta niin sanotut puhtaat spektrit, ja vastaamaan ensisijaisesti kysymykseen, mitä materiaaleja kohteessa on, ja toissijaisesti, mitkä ovat niiden määrälliset suhteet (Adams & Gillespie 2006: 48). Nämä analyysimenetelmät soveltavat konveksigeometriaa ja ovat käytettävissä vain lineaarisesti sekoittuneiden spektrien tulkintaan. Lineaarisuusvaatimus aiheuttaa tiettyjä ongelmia, koska sekoittuminen on lähes aina epälineaarista. Monesti kuitenkin epälineaaristakin sekoittumista voidaan approksimoida lineaaristen mallien avulla, varsinkin kaukokartoituksen kontekstissa, jolloin tarkastelumittakaava on niin laaja, että lineaarinen sekoittuminen alkaa olla hallitsevaa (Manolakis ym. 2016: 444).

3.2 Sensorit ja alustat

Kaikki hyperspektrisensorit toimivat pääpiirteissään samalla tavalla. Sensoriin kuuluu kolme pääkomponenttia: skanneri, kuvantamisjärjestelmä ja spektrometri. Skannerin tehtävänä on koota maan pinnalta tuleva sähkömagneettinen säteily ja määrittää sen sijainti kuvassa. Kuvantamisjärjestelmä muodostaa skannerilta tulevan säteilyn perusteella kuvan, josta spektrometri mittaa saapuvan energian tasot usealta eri aallonpituusalueelta. Sensorissa siis tapahtuu spatiaalista, spektristä ja radiometristä signaalinkäsittelyä (Manolakis ym. 2016: 8).

Hyperspektrisensori kokoaa keräämänsä arvot kolmiulotteiseen tietorakenteeseen, niin sanottuun datakuutioon (Kuva 5). Tämä johtaakin erääseen sensoreiden suurimmis-

ta haasteista, eli kuinka täyttää kolmiulotteinen tietorakenne, kun säteilyä mittaavien ilmaisimien on oltava kaksiulotteisessa tasossa, janaassa tai yksittäin. Ongelmaan löytyy kolme ratkaisuvaihtoehtoa: koko spektrin skannaaminen yksi rasteriruutu kerrallaan, koko spektrin skannaaminen jana kerrallaan tai koko kuvattavan alueen skannaaminen aallonpituuskanava kerrallaan (Manolakis ym. 2016: 9-10).

Tiedonkeruuta yksi rasteriruutu kerrallaan kutsutaan across-track- tai whiskbroom-skannaamiseksi. Tämän tyylinen tiedonkeruu vaatii liikkuvaa skanneriä, joka joko pyörivän tai kääntyvän peilin avulla kykenee muodostamaan skannauslinjoja kohtisuoraan mittausalustan liikesuuntaan nähden. Kaksiulotteinen kuva saadaan muodostettua alustan liikkeessä eteenpäin ja jatkuvien skannauslinjojen muodostaessa tason. Skannerin keräämä säteily hajotetaan prisman tai optisen hilan avulla spektriksi, joka eri osia voidaan mitata tarkasti sijoitetulla elektro-optisten ilmaisimien rivillä, jossa ilmaisimia on yhtä paljon kuin haluttuja aallonpituuskanavia (Lillesand ym. 2015: 219).

Mikäli skannaaminen halutaan tehdä koko jana kerrallaan, voidaan käyttää niin sanottua along-track- eli pushbroom-skannaamista. Whiskbroom-skannaamisen tapaan säteilyä mitataan janoittain ja kaksiulotteinen kuva muodostuu alustan liikkeen seurauksena, mutta tästä poiketen pushbroom-skannerista puuttuu peili, ja säteily mitataan koko janalta samanaikaisesti. Mittaamisesta vastaa jopa tuhansista CCD-kennoista (Charge-Coupled Device) koostuva kehikko, jonka rivit muodostavat halutut spektrikanavat ja sarakkeet vastaavat yhden pikselin spektrijakaumaa (Peleg ym. 2005). Pushbroommenetelmän etuna on sen parempi luotettavuus ja kesto, sekä sensoreiden pidempi vastaanottoaika, joka johtaa vahvempaan signaaliin. Heikkouksia menetelmällä on tuhansien yksittäisten sensoreiden vaatima kalibrointi ja suhteellisen suppea aallonpituusalue, jolla sensorit toimivat (Lillesand ym. 2015: 226).

Tietoa ei suinkaan ole mahdollista kerätä vain pikseli tai jana kerrallaan, vaan myös koko kuvan kerralla tallentavia menetelmiä on kehitetty. Tähän niin sanottuun snapshot-kuvaamiseen on useita erilaisia lähestymistapoja, joille yhteistä on usein niiden huomattava monimutkaisuus. Kuvaamista voidaan tehdä esimerkiksi nestekidesuodattimien avulla, joiden suodattamaa aallonpituutta voidaan muuttaa sähkövirran avulla (Ishida ym. 2018). Tallentamalla koko kuva kerralla saadaan kerättyä enemmän valoa lyhyemmässä ajassa.

Hyperspektrikameroita voidaan käyttää käytännössä kaikilla kaukokartoitusalueilla: satelliiteilla, lentokoneilla ja lennokeilla. Näistä jopa hieman yllättäen vähäisimmällä käytöllä ovat satelliitit, jotka ovat jo pitkään toimineet luotettavina alustoina multispektrisensoreille. Hyperspektrisensoreita on ollut sijoitettuina satelliitteihin vain muutamia, ja vaikka niillä onkin saatu tuotettua käyttökelpoista tutkimusaineistoa, liittyy satelliitti alustojen käyttöön monia ongelmia. Kiertoradalla toimivien sensoreiden kehittäminen on monimutkaista ja kallista, ja hyperspektrikuvauksen tuottaman valtavan datamäärän siirtäminen, tallentaminen ja käsitteleminen on hankalaa. Lisäksi satojen kilometrien korkeudesta kuvatessa varsinkin tietyillä aallonpituusalueilla signaalit alkavat olla turhan heikkoja. Kehitteillä on kuitenkin useampia uusia satelliittihankkeita, joihin kuuluu hyperspektrikameroita (Lillesand ym. 2015: 356-359).

Tyypillisin valinta hyperspektrikameran alustaksi on lentokone tai miehittämätön lennokki. Molempien hyviin puoliin kuuluu niiden joustavuus, tietoa voidaan kerätä vain halutulta alueelta, ja myös muita muuttujia, kuten lentokorkeutta ja kuvausajankohtaa voidaan helposti kontrolloida. Viimeisten noin viidentoista vuoden aikana hyperspektrisensorit ovat kuitenkin pienentyneet ja keventyneet, mikä on näkynyt etenkin lennokkipohjaisten ratkaisujen suosiossa. 2010-luvulla hyperspektrikuvauksen käyttö ympäristöntutkimuksessa onkin usein vahvasti kytkeytynyt erilaisten miehittämättömien ilma-alusten käyttöön, ja sitä kautta pienempien alueiden tarkempaan tutkimukseen (Bannerjee ym. 2020: 4138).

4 Sovellukset

Kuten jo todettua hyperspektrikuvauksen määrittävä ominaisuus on korkea spektrin resoluutio, ja tämä näkyy myös menetelmän sovelluskohteissa: hyperspektrikuvausta käytetään tilanteissa, joissa kohteita täytyy tunnistaa ominaisspektrissä olevien pienien eroavaisuuksien perusteella. Lähestulkoon kaikissa sovelluksissa peruseriaate on sama, eli hyperspektrikameran avulla pyritään havaitsemaan tiettyjen fyysisten tai kemiallisten kohteiden läsnäoloa ja määrää tutkimusalueella, ja käyttämään tätä tietoa indikaattorina muusta tutkittavasta ilmiöstä. Ehdottomasti eniten tutkimusta on tehty kasvillisuuden ja siitä johdettavien ilmiöiden parissa, mutta myös muun muassa geologista tutkimusta on menetelmällä tehty runsaasti. Tässä osiossa tarkastellaan erilaisia hyperspektrikuvausta

hyödyntäviä soveltavia tutkimuksia jaoteltuna kasvillisuustutkimuksiin ja muihin menetelmää hyödyntäviin tutkimuksiin.

4.1 Kasvillisuuden kartoittaminen

Hyvin suuri osa hyperspektrikuvausta kaukokartoituksessa soveltavista tutkimuksista on tehty kasvinäkökulmasta. Vaikka kasvit koostuvatkin heijastusominaisuuksiltaan erilaisista osista, kuten lehdistä ja oksista, määräytyy kaukokartoitusetäisyyksiltä mitattava ominaisspektri pääosin vihreiden lehtien tai muiden yhteyttävien osien mukaan. Luonnollisestikaan kaikki kasvilajit, tai edes saman kasvin eri lehdet, eivät heijasta valoa samalla tavalla, mutta vihreiden kasvinosien yhteydessä ominaisspektrissä on aina tietyt toistuvat piirteet, joiden perusteella tutkimusta tehdään (Tokola ym. 1998: 12).

Kasvillisuuden hyperspektritarkastelu tapahtuu useimmiten aallonpituusalueella 400–2700 nm, eli näkyvän valon sekä lähi- ja lyhytaaltoisen infrapunasäteilyn alueille. Ominaisspektristä erottuu selvästi kaksi aluetta, joilla säteilyenergiaa absorboituu runsaasti (Kuva 4). Klorofylli, ja vähäisemmässä määrin muut pigmentit, absorboi voimakkaasti ultraviolettisäteilyä ja näkyvän valon lyhyempiä aallonpituuksia, mikä voidaan havaita matalana heijastussuhteena 360–700 nm alueella. Vastaavanlainen, joskaan ei aivan yhtä voimakas, ilmiö voidaan havaita infrapunasäteilyn aallonpituuksilla 1300–3000 nm, joka kertoo kasveissa olevan vapaan veden absorboimasta energiasta (Tokola ym. 1998: 12). Lähi-infrapunasäteilyä kasvit eivät yleensä absorboi juuri lainkaan, vaan se heijastuu tai läpäisee kasvillisuuden lähes kokonaan. Ominaisspektrissä voidaankin havaita voimakas nousu näkyvän valon ja lähi-infrapunajan rajalla. Tämä niin sanottu ”red edge” kertoo paljon kasvin tilasta (Patel ym. 2001).

Yhteyttävien organismien ominaisspektrin perusteella voidaan tehdä hyvin monenlaista tutkimusta. Yksikertaisimpia sovelluksia ovat erilaiset luokittelut, joita käytetään etenkin maa- ja metsätaloudessa (Adão ym. 2017; Ishida ym. 2018), mutta luokittelua on tehty myös muissa ympäristöissä esimerkiksi rannikoiden vesikasvien kartoituksessa (Williams ym. 2003). Hyperspektriluokittelua on käytetty myös biodiversiteettitutkimuksen apuna (Gholizadeh ym. 2020; Saarinen ym. 2018). Pidemmälle vietyjä sovellutuksia ovat erilaiset kasvien tilaa ja mahdollisia stressitekijöitä kartoittavat menetelmät. Etenkin suhteellisen stabiilissa maatalousympäristössä ominaisspektrin perusteella voidaan tehdä tarkkojakin johtopäätöksiä kasvien tilasta. Muun muassa biomassassa, ve-

dentarve, ravinteidentarve ja mahdolliset kasvitaudit ovat tekijöitä, jotka voidaan havaita hyperspektrikuvauksen menetelmin (Thenkabail ym. 2002).

Vaikka erilaiset luokittelusovellukset ovatkin perusidealtaan kaikkein yksinkertaisimpia, ovat niiden käytännön toteutukset huomattavat monimutkaisia ja laskennallisesti raskaita. Luokittelu voidaan toteuttaa joko objekti- tai pikselipohjaisesti, ja näiden molempien vaihtoehtojen toteuttamiseen on useita erilaisia lähestymistapoja (Adão ym. 2017: 10-16). Luokittelu tapahtuu lähes poikkeuksetta automatisoidusti joko erilaisten luokittelualgoritmien tai erikoistuneiden neuroverkkojen avulla (Adão ym. 2017: 15). Hyperspektriaineiston manuaalinen luokittelu on mahdollista, mutta johtuen valtavista datamääristä tällaiselle luokittelulle on käyttöä vain hyvin pienillä alueilla arvioitaessa muiden menetelmien toimituutta (Ishida ym. 2018: 83). Huomionarvoista on, että luokittelun onnistumiseen vaikuttavat vahvasti kuvausolosuhteet (Ishida ym. 2018), ennen kuvausta mahdollisesti tehty sensoreiden kalibrointi (Tuominen ym. 2018) ja valitut luokittelumenetelmät (Rossiter ym. 2020). Onnistuessaan luokittelu on kuitenkin kohtuullisen tarkkaa. Esimerkiksi Tuominen ym. (2018) selvittivät hyperspektriluokittelun toimivuutta kouvolalaisessa arboretumissa puulajien tunnistamiseen. Yhdistämällä lähi- ja lyhytaaltoisen infrapunan kanavia kolmiulotteiseen pistepilveen tutkimusryhmä onnistui tunnistamaan tarkasteltujen puiden lajin 82 prosentissa tapauksista ja suvun 87 prosentissa tapauksista.

Eräs luokittelumenetelmien sovelluskohde on biodiversiteettitutkimus. Saarinen ym. (2018) käyttivät hyperspektrikuvausta yhdessä 3D-mallien kanssa selvittääkseen tutkimusalueen biodiversiteettiä erilaisten indikaattoreiden kautta. Miehitämättömään lennokkiin asennetulla hyperspektrikameralla kartoitettiin puuston lajirunsautta ja kuolleen puumateriaalin määrää samalla kun perinteinen digitaalikamera keräsi dataa pistepilveä varten, josta voitiin tehdä johtopäätöksiä puuston rakenteesta ja sukkession vaiheesta. Kaukokartoituksella saadut tulokset poikkesivat kenttätutkimuksena tehdyistä vertailuarvoista jonkin verran, mutta menetelmä vaikutti lupaavalta.

Hyperspektrikuvauksen käyttöä biodiversiteetin tutkimuksessa selvittivät myös Gholizadeh ym. (2020). Tutkimusryhmä pyrki selvittämään α - ja β -diversiteettiä ja niiden muutoksia Yhdysvaltojen ruohomailla. Tutkimusryhmän lähestymistapa biodiversiteetin selvittämiseen poikkesi selvästi Saarinen ym. (2018) käyttämästä metodista. Ilmakuvausena suoritettun hyperspektrikuvauksen tavoitteena ei ollut tunnistaa yksittäisiä kohteita tai lajeja, vaan havaita niin sanottuja spektrilajeja. Spektrilajit edustivat erilai-

sia signaalin lähteitä tai spektrin päätejäseniä, ja vaikeivat ne välttämättä vastanneet-kaan kasvilajeja, kuvasi niiden moninaisuus alueen biodiversiteettiä. Menetelmän avulla oli mahdollista seurata biodiversiteettiä ja sen muutosta, joskin sen suorituskyky heikkeni ekosysteemin stabiloituessa.

Hyperspektrikuvausten avulla on mahdollista pureutua myös tarkemmin kasvillisuuden tilaa. Thenkabail ym. (2002) selvittivät, kuinka hyperspektrisensorin kapeiden aallonpituuskanavien avulla päästään käsiksi maataloudelle tärkeisiin biofysikaalisiin muutuksiin, joita on aiemmin selvitetty erilaisten satelliittikuvista laskettujen kasvillisuusindeksien avulla. Tutkimusryhmä analysoi suuren määrän erilaisia kanavayhdistelmiä, ja tuli tulokseen, että kapeakanavaiset hyperspektrikuvat soveltuivat etenkin märkä- ja kuiva-biomassan sekä lehtialaindeksin määrittämiseen. Kahden tai kolmen kapean aallonpituuskanavan perusteella lasketun muuttujan avulla voitiin selittää selvästi suurempi osa vaihtelusta kuin normaalien satelliittikuvien avulla. Lisäksi kävi ilmi, että vain kahdentoista kapean aallonpituuskanavan avulla oli mahdollista päästä käsiksi maatalouden kannalta optimaalisiin biofysikaalisiin muuttujiin.

Eräs tärkeä käyttökohde hyperspektriaineistoille on kasvitautien ja -tuholaisten havaitseminen mahdollisimman aikaisin. Näsi ym. (2015) selvittivät hyperspektrikuvien tehoa kaarnakuoriaistartunnan havaitsemisessa kuusivaltaisissa talousmetsissä. Fotogrammetrian ja hyperspektridatan avulla oli mahdollista tunnistaa yksittäiset puut tutkimusalueella, ja luokitella ne kahteen tai kolmeen luokkaan mahdollisen tartunnan perusteella. Menetelmä kykeni erottelemaan puut kolmeen luokkaan (terve, saastunut, kuollut) keskimäärin 76 % tarkkuudella ja kahteen luokkaan (terve, kuollut) yli 90 % tarkkuudella. Menetelmän laajempi soveltaminen voisi mahdollistaa kaarnakuoriaistartunnan leviämisen seurannan ja mahdollisten torjuntatoimien tarkemman kohdistamisen.

4.2 Muut sovelluskohteet

Vaikka kasvillisuus onkin tyypillisin hyperspektrikartoituksen kohde, ei se suinkaan ole ainoa. Erilaisia sovelluksia on löytynyt hyvinkin monipuolisesti erilaisilta ympäristöntutkimuksen alueilta. Hyperspektrikuvausten avulla on päästy kiinni muun muassa indikaattorimineraalien tunnistamiseen (Ferrier & Wadge 1996; Jackisch ym. 2018), ympäristöön levinneiden hiilivetyjen havaitsemiseen (Hörig ym. 2001) ja vedenlaatuun vaikuttavien tekijöiden mittaamiseen (Koponen ym. 2002; Tuominen 2016). Kasvil-

lisuudesta poiketen näillä kohteilla ei lähtökohtaisesti ole ominaisspektreissään yhteneviä piirteitä, vaan tarkasteltavat aallonpituudet vaihtelevat merkittävästi kohteen mukaan.

Geologiseen kartoitukseen hyperspektrikuvausta on käytetty varsin rajoitetusti. Tämä on sikäli ymmärrettävää, että hyperspektrisensorit eivät kykene tunkeutumaan maanpintaa syvemmälle, jolloin useimpien geologisten ilmiöiden kartoittaminen ei onnistu. Tietyissä tapauksissa hyperspektrikuvaus voi sen sijaan olla hyvinkin toimiva ratkaisu, sillä useat mineraalit ovat optisesti aktiivisia. Mineraalien ominaisspektreihin vaikuttavat etenkin näkyvän valon ja lähi-infrapunan alueella siirtymämetallit, kuten rauta ja nikkeli, sekä lyhytaaltoisen infrapunan alueella vesi, hydroksyyli, karbonaatit ja sulfaatit (van der Meer ym. 2012). Näiden elementtien olemassaolo on mahdollista havaita ominaisspektrin absorptiopiirteissä, minkä lisäksi näiden piirteiden voimakkuuteen vaikuttaa kohteen raekoko.

Ferrier ja Wadge (1996) sovelsivat hyperspektrikuvausta potentiaalisten kultamineralisaatioiden etsimiseen. Taloudellisesti arvokkaita kultamineralisaatioita saattaa syntyä hydrotermisten fluidien muuttaessa kallioperän kiveä. Näille muuntumisvyöhykkeille ominaisia indikaattorimineraaleja voidaan havaita kaukokartoitusmenetelmin, mikäli ne ovat paljastuneet maan pinnalle. Ferrier ja Wadge käyttivät indikaattorimineraaleina aluniittia, pyrofylliittia, kaoliniittia, illiittia ja vermikuliittia, joilla on kaikilla tunnistettavia absorptiopiirteitä lyhyt aaltoisen infrapunan alueella, etenkin aallonpituusvälillä 1400nm-2200nm. Aluniitin tunnistaminen sujui onnistuneesti sen 1480 nanometrin ja 1760 nanometrin absorptiopiirteiden avulla. Myös muiden vesipitoisten muutosmineraalien sijainnin ja määrän arvioiminen onnistui aallonpituus alueella 2000nm-2400nm olevien piirteiden avulla, joskaan Ferrier ja Wadge eivät onnistuneet erottamaan näitä mineraaleja toisistaan.

Myös Jackisch ym. (2018) käyttivät lennokkialustaista hyperspektrikuvausta indikaattorimineraalien tunnistamiseen tavoitteenaan selvittää kaivosten happamien valumavesien leviämistä ympäristöön. Hapen ja veden vaikutuksesta etenkin erilaiset rautasulfidimineraalit rapautuvat ja vapauttavat ympäristöön pH-arvoa laskevia ioneja. Happamista valumavesistä saostuu erilaisia rautapitoisia sekundaarimineraaleja, jotka toimivat todisteena happamien valumavesien syntymisestä ja leviämisestä, ja jotka voidaan havaita hyperspektrikuvista. Jackisch ym. (2018) käyttivät tutkimuksessaan indikaattorimineraaleina jarosiittia ja goethiittia, joilla on useita tunnistettavia absorptiopiirteitä näkyvän

valon, lähi-infrapun ja lyhytaaltoisen infrapun alueilla. Mineraalien kartoittaminen sujui onnistuneesti, ja niiden pohjalta voitiin myös tehdä karkeita arvioita pH-arvosta.

Hyperspektrikuvausta voidaan käyttää myös muiden kemiallisten yhdisteiden tunnistamiseen. Hiilivedyillä on tunnistettavat absorptiopiirteet lyhytaaltoisen infrapunäteilyn alueella 1730 nanometrin ja 2310 nanometrin ympärillä, joiden perusteella Hörig ym. (2001) pyrkivät tunnistamaan hiilivety-yhdisteitä sisältävät koealueet hyperspektrikuvien perusteella. Koealueet täytettiin öljystä saastuneella hiekalla, erivärisillä muovisilla suojapeitteillä ja läpinäkyvillä muoviarkeilla sekä erilaisilla vertailuarvoina käytettävillä materiaaleilla, kuten puhtaalla hiekalla. Testin tuloksena selvisi, että lyhyt aaltoisen infrapun absorptiopiirteiden avulla on mahdollista tunnistaa hiilivetyjä sisältävät kohteet ympäristöstään, jonka lisäksi joissakin tapauksissa näkyvän valon ja lähi-infrapun avulla voidaan eritellä eri hiilivetyjä sisältävät materiaalit.

Järvien vedenlaatu on monen tekijän summa, ja sitä voidaan arvioida lukuisien eri muuttujien avulla. Näistä seitsemää voidaan arvioida optisen kaukokartoituksen, yleensä hyperspektrikuvien, avulla (Koponen 2006; Tuominen 2016). Nämä seitsemän ovat kasviplanktonin määrä, epäorgaanisen materiaalin määrä, humuksen määrä, sameus, näkösyvyys, lämpötila sekä leväkukintojen määrä ja levinneisyys. Perinteisesti vedenlaatua on seurattu kiinteiltä havaintopaikoilta otettujen vesinäytteen ja paikan päällä tehtyjen mittausten avulla. Kaukokartoitusmenetelmien avulla voidaan kattaa suurempia alueita ja toistaa mittauksia useammin, jolloin päästään myös paremmin kiinni vedenlaadun alueelliseen vaihteluun. Rajoituksena toki on mitattavien tekijöiden pienempi määrä.

Koponen ym. (2002) selvittivät hyperspektrisen kaukokartoituksen soveltuvuutta järvien vedenlaadun luokitteluun. Menetelmää testattiin yhdessätoista eteläsuomalaisessa järvessä, joiden trofinen tila vaihteli eutrofisesta oligotrofiseen ja dystrofiseen. Dataa kerättiin lentokoneeseen asennetulla hyperspektrikameralla kahdeksan lennon aikana neljällekkymmenelle tai viidellekkymmenelle näkyvän valon ja lähi-infrapun alueelle osuvalle kanavalle. Tavoitteena oli datan perusteella arvioida koejärvien veden näkösyvyyttä, sameutta ja klorofylli a:n määrää. Aallonpituuskanavat vedenlaatumuutujia varten saatiin selville empiirisesti muodostamalla regressiomalli kaikille kanaville ja kanavayhdistelmille, ja valitsemalla niiden joukosta parhaiten dataan soveltuva malli. Tuloksena selvisi, että hyperspektrikartoitus soveltuu vedenlaadun luokitteluun, luokittelutarkkuuden ollessa 76–90 %.

5 Pohdinta

Kuten olemme useista esimerkeistä nähneet, on hyperspektrikuvaus erittäin monipuolinen kaukokartoitusmenetelmä. Kaikki reaali maailman objektit heijastavat sähkömagneettista säteilyä tai tuottavat sitä itse, joten niitä voidaan havainnoida kaukokartoituksen menetelmin. Hyperspektrikuvaus mahdollistaa kohteiden tarkastelun nanometriluokan spektrisellä resoluutiolla, jolloin potentiaaliset käyttökohteet ovat huomattavasti runsaslukuisempia, kuin mitä tämän tutkielman puitteissa voidaan esitellä.

Arvioitaessa uuden tutkimusmenetelmän käyttökelpoisuutta ja arvoa tieteenteolle tulee kuitenkin olla varovainen. Uutta lupaavaa menetelmää tulee helposti tarkasteltua ruusunpunaisten linssien läpi, mutta todellisuus on usein harmaampi, näin myös hyperspektrikuvauksen tapauksessa. Vaikka käyttökohteita hyperspektrikuvaukselle on löytynyt lukuisia, ja tutkijat ovat jatkuvasti kehittäneet menetelmää eteenpäin, liittyy siihen silti vielä useita käyttöä hankaloittavia tai jopa estäviä tekijöitä.

5.1 Rajoitukset

Ehdottomasti merkittävin hyperspektrikuvauksen laajempaa kaukokartoituskäyttöä rajoittava tekijä on menetelmän huomattava monimutkaisuus. Hyperspektrikuvaamisen onnistunut hyödyntäminen vaatii runsaasti hyvin pitkälle erikoistunutta osaamista. Menetelmää käyttävästä tutkimusryhmästä on löydettävää vankkaa tietotaitoa paitsi kaukokartoituksesta ja kuvien analysoinnista, myös kartoitettavasta kohteesta ja etenkin sen spektrisistä ominaisuuksista. Tätä tietoa löytyy erikoistuneiden tieteenalojen, kuten biologian ja geologian osajien joukosta, mutta ominaisspektreihin ja niiden hyödyntämiseen liittyvä osaaminen voi vielä toistaiseksi olla puutteellista.

Hyperspektrikuvauksen onnistunut hyödyntäminen on riippuvaista huolellisesti tehdyistä esivalmisteluista. Kun kuvauksen spatiaalinen ja spektrinen resoluutio ovat korkeita, syntyy aineistoon myös helpommin merkittäviä virheitä. Esimerkiksi kenttätutkimuksessa vaihtelevat valaistusolosuhteet voivat vaikuttaa mittaustuloksiin (Hakala ym. 2013). Muutokset pilvipeitteessä, tai niinkin yksinkertaiset asiat kuin auringonvalon tulokulman vaihtelu, voivat vaikuttaa merkittävästi tuloksiin. Näiden ja muiden vastaavien tekijöiden vaikutusta voidaan kuitenkin ehkäistä huolellisilla valmisteluilla ja aineiston jälkikäsitteilyllä.

Hyperspektridatan analysoiminenkaan ei ole yksinkertainen tehtävä. Ensimmäisen haasteen muodostaa hyperspektrisensoreiden keräämän datan valtava määrä. Riippuen käytettävien aallonpituuskanavien määrästä, voi analysoitava datamäärä muuttua monikymmenkertaiseksi verrattuna muihin menetelmiin, eikä kaikkia aallonpituuskanavia voida analysoida samoin menetelmin. Ilmakehän ja vaihtelevien olosuhteiden aiheuttamien virheiden korjaaminen ja sekoittuneiden spektrien tunnistaminen lisäävät oman työnsä analyysiprosessiin.

Hyperspektrikuvauksien toistettavuuteen liittyy ainakin vielä toistaiseksi suhteellisen merkittäviä ongelmia. Kamerateerit on pääosin kalibroitu laboratorioden standardoiduissa olosuhteissa, joissa ei tapahdu muutoksia esimerkiksi ilmakehässä tai valaistusolosuhteissa, toisin kuin kenttämittauksia tehtäessä. Ongelmia on niin kuvien spatiaalisessa kuin spektrisessäkin toistettavuudessa, ja tästä aiheutuva varianssi on pahimmillaan samaa suuruusluokkaa tavoitellun informaation oman varianssin kanssa (Peleg ym. 2005).

5.2 Tulevaisuus

Kaukokartoitukseen soveltuvaa hyperspektritekniologiaa on ollut olemassa vasta noin neljäkymmenen vuoden ajan, ja laajasti saataville se on tullut vasta noin viimeisimpien kahden vuosikymmenen aikana. Menetelmä on siis kaukokartoituskäytössä vasta varsin uusi lähestymistapa aiheeseen, ja tulee todennäköisesti tulevaisuudessa näkemään entistä laaja-alaisempaa käyttöä niin tutkimuksessa kuin kaupallisissakin sovelluksissa (Adão ym. 2017). Menetelmän leviämistä edistää samaan aikaan nopeasti kehittyvät miehittämättömät ilma-alukset, joiden käyttö on satelliitteihin ja lentokoneisiin verrattuna paitsi halvempaa, myös joustavampaa ja logistisesti helpompaa. Hyperspektrikuvauksen kehitys tulevaisuudessa on muutenkin vahvasti kytköksissä teknologiseen kehitykseen. Itse hyperspektrikamerateerit ovat jatkuvan teknologisen kehitystyön alaisia, ja niiden koko pienenee ja ominaisuudet paranevat vuosi vuodelta. Vastaavasti datan käsittelyyn ja käsittelyprosessien automatisointiin käytettävät ohjelmistot ja tietokoneet kehittyvät jatkuvasti.

Teknologia yksin ei kuitenkaan riitä takaamaan laajaa tulevaisuuden käyttöä, vaan se vaatii myös panostuksia tieteen tekijöiden puolelta. Parhaimmallaan teknologialla ei ole paljoa tarjottavaa, mikäli sitä ei osata käyttää tai sitä käytetään kohteissa, joihin se ei sovellu. Osaamisen ja sopivien käyttökohteiden puute tuskin kuitenkaan

tulee olemaan este, kuten tässäkin työssä käytettävistä esimerkkitutkimuksista voidaan havaita. Tutkijat ovat tarttuneet innokkaasti menetelmään, ja aiheeseen liittyvää uutta tutkimusta tehdään jatkuvasti.

Hyperspektrikameroilla tehtävän kaukokartoituksen ehdoton etu on se, menetelmällä on kaupallisia sovelluksia. Etenkin maa- ja metsätalouden puolella on runsaasti kysyntää kartoitusmenetelmälle, jolla saadaan kerättyä laajalta alueelta luotettavaa tietoa viljelykasvien ja puuston tilasta, ja jonka avulla voidaan nopeasti reagoida muutoksiin kasvuolosuhteissa. Nämä ja monet muut käyttökohteet paitsi tuovat menetelmälle näkyvyyttä, myös edistävät hyperspektritutkimuksen rahoitusta.

Kokonaisuutena hyperspektrikuvaus on jo saanut jalansijaa muiden, perinteisempien, kaukokartoitusmenetelmien joukosta, eikä kehitys varmasti ole jäämässä tähän. Kunhan miehittämättömät kuvausalustat ja valtavan datamäärän analysointiin tarvittavat ohjelmistot ja analyysimenetelmät kehittyvät hieman pidemmälle, tulee hyperspektrikuvaus varmasti leviämään laajempaan käyttöön. Tämä kuitenkin luonnollisesti vaatii kiinnostusta ja panostusta myös tutkijoiden ja etenkin nuoremman tutkijasukupolven puolelta, sillä hyperspektrikuvausmenetelmän luotettava ja onnistunut käyttäminen tutkimukseen vaatii varsin pitkälle menevää erikoistumista.

6 Kirjallisuutta

- Adams, J. & Gillespie, A. (2006). *Remote Sensing of Landscapes with Spectral Images: A Physical Modeling Approach*. Cambridge University Press, Cambridge.
- Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R. & Sousa, J. J. (2017). Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote Sensing* 9(11). <http://dx.doi.org/10.3390/rs9111110>.
- Banerjee, B. P., Raval, S. & Cullen, P. J. (2020). UAV-hyperspectral imaging of spectrally complex environments. *International Journal of Remote Sensing* 41(11) 4136–4159. <http://dx.doi.org/10.1080/01431161.2020.1714771>.
- Borengasser, M., Hungate, W. & Watkins, R. (2008). *Hyperspectral remote sensing: principles and applications*. CCR Press, Boca Raton.
- Campbell, J. B. (2002). *Introduction to remote sensing*. 3. painos. Guilford Press, New York.
- Dodge, R. L. & Congalton, R. G. (2013). *Meeting Environmental Challenges with Remote Sensing Imagery*. AGI Publications, Alexandria.
- Ferrier, G. & Wadge, G. (1996). The application of imaging spectrometry data to mapping alteration zones associated with gold mineralization in southern Spain. *International Journal of Remote Sensing* 17(2) 331–350. <http://dx.doi.org/10.1080/01431169608949009>.
- Gholizadeh, H., Gamon, J. A., Helzer, C. J. & Cavender-Bares, J. (2020). Multi-temporal assessment of grassland α - and β -diversity using hyperspectral imaging. *Ecological Applications* 30(7) 1–13. <http://dx.doi.org/10.1002/eap.2145>.
- Hakala, T., Honkavaara, E., Saari, H., Mäkynen, J., Kaivosoja, J., Pesonen, L. & Pölonen, I. (2013). Spectral imaging from UAVs under varying illumination conditions. Teoksessa *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, osa XL-1/W2, 189–194.

- Hörig, B., Kühn, F., Oschütz, F. & Lehmann, F. (2001). HyMap hyperspectral remote sensing to detect hydrocarbons. *International Journal of Remote Sensing* 22(8) 1413–1422. <http://dx.doi.org/10.1080/01431160120909>.
- Ishida, T., Kurihara, J., Viray, F. A., Namuco, S. B., Paringit, E. C., Perez, G. J., Takahashi, Y. & Marciano, J. J. (2018). A novel approach for vegetation classification using UAV-based hyperspectral imaging. *Computers and Electronics in Agriculture* 144 80–85. <http://dx.doi.org/10.1016/j.compag.2017.11.027>.
- Jackisch, R., Lorenz, S., Zimmermann, R., Möckel, R. & Gloaguen, R. (2018). Drone-borne hyperspectral monitoring of acid mine drainage: An example from the Sokolov lignite district. *Remote Sensing* 10(3). <http://dx.doi.org/10.3390/rs10030385>.
- Koponen, S. (2006). *Remote sensing of water quality for Finnish lakes and coastal areas*. väitöskirja, Helsinki University of Technology.
- Koponen, S., Pulliainen, J., Kallio, K. & Hallikainen, M. (2002). Lake water quality classification with airborne hyperspectral spectrometer and simulated MERIS data. *Remote Sensing of Environment* 79(1) 51–59. [http://dx.doi.org/10.1016/S0034-4257\(01\)00238-3](http://dx.doi.org/10.1016/S0034-4257(01)00238-3).
- Lillesand, T., Kiefer, R. & Chipman, J. (2015). *Remote sensing and image interpretation*. 7. painos. John Wiley & Sons, New York.
- Manolakis, D., Lockwood, R. & Cooley, T. (2016). *Hyperspectral Imaging Remote Sensing-Physics, Sensors, and Algorithms*. Cambridge University Press, Cambridge.
- Näsi, R., Honkavaara, E., Lyytikäinen-Saarenmaa, P., Blomqvist, M., Litkey, P., Hakala, T., Viljanen, N., Kantola, T., Tanhuanpää, T. & Holopainen, M. (2015). Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. *Remote Sensing* 7(11) 15467–15493. <http://dx.doi.org/10.3390/rs71115467>.
- Patel, N. K., Patnaik, C., Dutta, S., Shekh, A. M. & Dave, A. J. (2001). Study of crop growth parameters using Airborne Imaging Spectrometer data. *International Journal of Remote Sensing* 22(12) 2401–2411. <http://dx.doi.org/10.1080/01431160117383>.

- Peleg, K., Anderson, G. L. & Yang, C. (2005). Repeatability of hyperspectral imaging systems - Quantification and improvement. *International Journal of Remote Sensing* 26(1) 115–139. <http://dx.doi.org/10.1080/01431160412331291288>.
- Rossiter, T., Furey, T., McCarthy, T. & Stengel, D. B. (2020). UAV-mounted hyperspectral mapping of intertidal macroalgae. *Estuarine, Coastal and Shelf Science* 242. <http://dx.doi.org/10.1016/j.ecss.2020.106789>.
- Saarinen, N., Vastaranta, M., Näsi, R., Rosnell, T., Hakala, T., Honkavaara, E., Wulder, M. A., Luoma, V., Tommaselli, A. M., Imai, N. N., Ribeiro, E. A., Guimarães, R. B., Holopainen, M. & Hyypä, J. (2018). Assessing biodiversity in boreal forests with UAV-based photogrammetric point clouds and hyperspectral imaging. *Remote Sensing* 10(2). <http://dx.doi.org/10.3390/rs10020338>.
- Thenkabail, P. S., Smith, R. B. & De Pauw, E. (2002). Evaluation of narrowband and broadband vegetation indices for determining optimal hyperspectral wavebands for agricultural crop characterization. *Photogrammetric Engineering and Remote Sensing* 68(6) 607–621.
- Tokola, T., Hyppänen, H., Miina, S., Vesa, L. & Anttila, P. (1998). *Metsän kaukokartoitus*. Joensuun yliopisto, Metsätieteellinen tiedekunta, Joensuu.
- Tuominen, J. (2016). *Hyperspectral Remote Sensing of Coastal Environment*. väitöskirja, Tampere University of Technology.
- Tuominen, S., Näsi, R., Honkavaara, E., Balazs, A., Hakala, T., Viljanen, N., Pölönen, I., Saari, H. & Ojanen, H. (2018). Assessment of classifiers and remote sensing features of hyperspectral imagery and stereo-photogrammetric point clouds for recognition of tree species in a forest area of high species diversity. *Remote Sensing* 10(5) 1–28. <http://dx.doi.org/10.3390/rs10050714>.
- van der Meer, F. D., van der Werff, H. M., van Ruitenbeek, F. J., Hecker, C. A., Bakker, W. H., Noomen, M. F., van der Meijde, M., Carranza, E. J. M., de Smeth, J. B. & Woldai, T. (2012). Multi- and hyperspectral geologic remote sensing: A review. *International Journal of Applied Earth Observation and Geoinformation* 14(1) 112–128. <http://dx.doi.org/10.1016/j.jag.2011.08.002>.

Williams, D. J., Rybicki, N. B., Lombana, A. V., O'Brien, T. M. & Gomez, R. B. (2003). Preliminary investigation of submerged aquatic vegetation mapping using hyperspectral remote sensing. *Environmental Monitoring and Assessment* 81(1-3) 383–392. <http://dx.doi.org/10.1023/A:1021318217654>.