



UNIVERSITY OF
EASTERN FINLAND

Luonnontieteiden ja metsätieteiden

tiedekunta

Faculty of Science and Forestry

MÄNNYN LEHTIALAINDEKSIN JA BIOMASSAN MALLINNUS SODSAR-
TUTKALLA

Riku Tarvainen

METSÄTIETEEN PRO GRADU TUTKIELMA

JOENSUU 2021

Tarvainen, Riku. 2021. Männyn lehtialaindeksin ja biomassan mallinnus SodSAR-tutkalla. Itä-Suomen yliopisto, luonnontieteiden ja metsätieteiden tiedekunta, metsätieteiden osasto. Metsätieteen pro gradu, erikoistumisala metsänarviointi ja metsäsuunnittelu. 46 s.

TIIVISTELMÄ

Lehtialaindeksi ja biomassa ovat tärkeässä ja ajankohtaisessa roolissa metsien kaukokartoituksessa. Molemmat parametrit ovat avainasemassa, kun lasketaan hiilensidontaan, fotosynteesiin ja metsien tilaan liittyviä arvioita. Näiden laskelmien avulla saadaan uutta tietoa myös ilmastomuutoksesta, sen ennaltaehkäisystä ja sen aiheuttamista vaikutuksista. Ne kertovat myös metsien kunnosta ja kasvusta metsätalouden näkökulmasta. Molempia parametreja on työlästä mitata käsin, joten kaukokartoitusmenetelmiä on tutkittu ja kehitetty viime vuosikymmenien aikana intensiivisesti.

Tässä tutkimuksessa tarkasteltiin torniin kiinnitettyä synteettisen apertuurin mikroaaltotutkaa lehtialaindeksin ja biomassan arvioinnissa. Laitteisto ja havainnoitava metsä sijaitsevat Sodankylässä, Ilmatieteen laitoksen Arktisen tutkimuslaitoksen alueella. Metsä on noin 50 m x 50 m kokoinen karu kangas, jonka ainoa puulaji on mänty. Metsään ei ole tehty minkäänlaisia metsänhoidollisia toimenpiteitä yli 80 vuoteen. Alueelta otettiin 5 metrin välein taivasta vasten kuvia, joista LAI-arvo laskettiin. Puustoaineisto kattaa jokaisen yli 5 cm paksun puun mitat ja sijainnin, jotka kerättiin kesällä 2019. Tutka-aineistona käytettiin X-L-kanavien rasteita, jotka keskiarvotettiin karkeampaan hilakokoon. LAI:n tapauksessa käytettiin 10 metrin rasteria ja biomassan tapauksessa 5 metristä.

Aikaisempien tutkimusten perusteella tutka pystyy havaitsemaan LAI:n kohtuullisen tarkasti. Varsinkin C- ja X-kanavat ovat käyttökelpoisia johtuen lyhyestä aallonpituudesta. LAI ja biomassa ovat vahvasti sidoksissa oksien ja lehtien määrään, joten lyhyet aallonpituudet havainnoivat nämä voimakkaimmin. Tulosten perusteella C-kanavasta johdetut mallit toimivatkin parhaiten, selitysasteen vaihdellessa eri vuodenaikojen välillä 0,53-0,66. Suoraa vertailua vaikeuttaa kuitenkin aineistojen epäyhteinäisyys.

Tutkan avulla yritettiin mallintaa yksittäisten puiden biomassaa, mutta tulokset eivät olleet hyviä. C- ja S-kanavista johdetut tilastolliset mallit pystyivät selittämään vain suurimpien puiden biomassaa. Kun aineistona käytettiin kaikkia puita, ei minkään kanavan malli selittänyt vaihtelua tilastollisesti merkitsevästi.

Avainsanat: Synteettisen apertuurin tutka, lehtialaindeksi, biomassa

Tarvainen, Riku. 2021. Leaf area index and biomass models of Scots Pine with SodSAR. University of Eastern Finland, Faculty of Science and Forestry, School of Forest Sciences. Master's thesis in Forest Science, specialization Forest Mensuration and Forest Planning. 46 p.

ABSTRACT

Leaf area index and biomass play an important role in field of remote sensing of forests. Both parameters play a key role in calculating estimates related to carbon sequestration, photosynthesis, and forest status. These calculations will also provide new information on climate change, its prevention, and its impacts. Both parameters are laborious to measure manually, so remote sensing methods have been intensively studied and developed during recent decades.

This study focuses on tower-based synthetic aperture microwave radar and its ability to observe leaf area index and biomass. The equipment and the forest to be observed are located in Tähtelä Sodankylä, in the area of the Arctic Research Institute of the Finnish Meteorological Institute. Area of forest is approximately 50 m x 50 meters. Vegetation is very poor, soil is dry and Scots Pine (*Pinus sylvestris*) is only tree species. No forest management actions have been carried out in the forest for more than 80 years. LAI was measured from the pictures taken by using fisheye lens. Systematic 5 x 5 meters grid was established for pictures location. LAI was measured at three different seasons: before and after growing season and once in winter. Tree data was collected in summer 2019 and covers the dimensions and location of each tree over 5 cm thick. Tree height, diameter, crown height and location were measured. SAR-images from band X to L with linear values were used as response data. Images were resampled to 10-meter resolution.

Previous studies have shown that the radar can observe LAI and biomass with reasonable accuracy. Especially C- and X- bands are useful due their shorter wavelength. LAI and biomass correlate strongly with branches and leaves and shorter wavelengths returns stronger signal from crown. Based on the results, C-band regression model explained LAI-values best $R^2 = 0,53 - 0,66$. However, direct comparison is complicated by the heterogeneity of the datasets.

Radar was used to try to model the biomass of individual trees, but the results were not good. Statistical models derived from channels C and S were only able to explain the biomass of the largest trees. When all trees were used as data, the model of any channel did not explain the variation statistically significantly.

ALKUSANAT

Tämä Pro Gradu- tutkielma toteutettiin Ilmatieteen laitoksen alaisuudessa, Sodankylän Arktisessa Tutkimuskeskuksessa. Kiitos taloudellisesta tuesta sekä asiantuntevasta avusta koko laitokselle sekä erityisesti Kaukokartoitus- ja avaruustutkimus-yksikölle sekä Sodankylän paikallisille työntekijöille.

Sisällysluettelo

1. JOHDANTO	6
1.1 Kaukokartoitus.....	6
1.2 Tutka	7
1.3 Lehtialaindeksi ja biomassa	10
1.4 Tutkat metsien kaukokartoituksessa.....	12
2. MATERIAALIT JA MENETELMÄT	16
2.1 Lehtialakuvat	17
2.2 Puustotiedot ja biomassa	20
2.3. Sodankylä Synthetic Aperture Radar.....	21
SodSAR tekniset ominaisuudet.....	24
2.4 Tilastolliset menetelmät.....	27
3. TULOKSET	30
3.1. Lehtialaindeksi.....	30
3.2. Biomassa.....	36
4. TULOSTEN TARKASTELU	39
4.1. Lehtialaindeksi.....	39
4.2. Biomassa.....	40
5. LÄHTEET	42

1. JOHDANTO

1.1 Kaukokartoitus

Kaukokartoituksella tarkoitetaan kohteen havainnointia ilman fyysistä lähikosketusta. Menetelmä perustuu kohteen sirottaman tai emitoiman sähkömagneettisen säteilyn havainnointiin. Säteilyä voidaan itse tuottaa, jolloin menetelmä on aktiivinen kaukokartoitus. Toinen tapa on havainnoida passiivisesti kohteen itsensä tuottamaa säteilyä esim. radiometrillä tai auringosta lähtevää säteilyä optisilla kuvausmenetelmillä. Kaukokartoitus tapahtuu ilmasta käsin dronilla tai lentokoneella, tai kiertoradalta satelliitin avulla. Kerätyn tiedon tukena on yleensä tarkentavaa manuaalisesti mitattua referenssitietoa kuten maastokoealoja tulkinnan avuksi, mittalaitteen kalibroimiseksi ja tulosten oikeellisuuden varmistamiseksi. Kerätty tieto on hyvin objektiivista ja yksikkökustannuksiltaan kustannustehokasta, koska tietoa saadaan yhdellä mittauskerralla suuria määriä. Suuri hyöty saadaan laajoilla ja vaikeasti saavutettavilla alueilla, mutta toisaalta se soveltuu kaiken kokoisiin kohteisiin. Kartoituksen avulla kerätään tietoa yksittäisistä kohteista, muutaman metrin paikallisista alueista ja suuremmista alueista, jolloin mittakaava voi olla kuntatasolta maapallon kattavaa. Spatiaalisen erotuskyvyn lisäksi myös ajallinen tarkkuus on satelliittien ansiosta hyvä, jolloin menetelmä soveltuu hyvin muutosten seurantaan. Suomessa metsävaratietoa kerätään paljon kaukokartoitusmenetelmillä ja sitä hyödynnetään erityisesti kuviotason metsän arvioinnissa, operatiivisessa puunhankinnassa, metsäkiinteistöjen hallinnassa ja arvonmäärityksessä sekä otantapohjaisessa suurten alueiden inventoinnissa. Menetelmänä on yleensä laserkeilaus, mutta sen tukena käytetään tutka-, ilma- ja satelliittikuvia sekä maastosta kerättyä metsävaratietoa (Kangas, A. ym. 2011). Kaikissa menetelmissä on omat vahvuutensa ja heikkoutensa. Optiset kuvat kuten satelliitti- ja ilmakuvat toimivat ainoastaan selkeällä säällä ja päiväaikaan, koska ne vastaanottavat auringonsäteilyä. Pilvet, sade, varjot ja pimeys haittaavat silloin erotuskykyä. Laserkeilaus on, pulssitiheydestä riippuen, menetelmistä kaikkein tarkin, mutta samalla myös kallein. Vaikka sillä onnistuu suurtenkin alueiden kartoitus, se ei ole yhtä tehokas globaalien ilmiöiden seurantaan. Tutkan ominaisuuksista lisää luvussa 1.2.

1.2 Tutka

1.2.1 Taustaa


Tutka (RADAR = **RA**dio **D**etection and **R**anging) on laite, joka lähettää mikroaaltosäteilyä kuvattavaa kohdetta kohti ja mittaa takaisinsironneesta tehosta joko pelkän amplitudin (skatterometri), tai sekä amplitudin että vaiheen. Vertaamalla vastaanotettua signaalia lähetyssignaaliin saadaan myös mitattua kulku-aika. Mikroaaltojen aallonpituusalue 1 mm – 1 m. Kaukokartoitusmielessä tutkat ovat hyödyllisiä, koska mikroaallot pystyvät läpäisemään useita väliaineita, mm. Ilmakehää, näkyvän valon aallonpituuksia paremmin. Lisäksi mikroaallot saattavat viestiä jotain muuta kuin näkyvä pinta antaisi olettaa, koska ne eivät ole suorassa suhteessa kappaleen näkyvään osaan (Lillesand ym. 2004) Esim. metsien kaukokartoituksessa tutkilla voidaan, aallonpituudesta riippuen, läpäistä neulasten, oksien ja latvuston muodostama kerros ja havainnoida niiden peittämää maanpintaa. Menetelmän heikkous on vaativa laitteisto ja se ettei kuvaa pystytä tuottamaan välittömästi. Itse tutka on monimutkaista tekniikkaa, joka vaatii tekijältä ja käyttäjältä laajempaa ymmärrystä kuin normaalin ilmakuvan tuottaminen. Lisäksi tutkan keräämä aineisto vaatii yleensä raskasta laskentaa, varsinkin jos tavoitellaan tarkkaa resoluutiota (Richards ym. 2010).

Tutka kehitettiin havaitsemaan kohteita niiden heijastamien radioaaltojen perusteella. Lähetetyn ja vastaanotetun pulssin aike-ero kertoi etäisyyden, suuntaavalla antennilla saatiin arvio kohteen suunnasta. Nykyisin yleisiä käyttökohteita tutkille on mm. nopeudenvälvonta, joka on myös esimerkki tutkasta, joka ei tuota minkäänlaista kuvaa. Siinä laite analysoi lähettämiään Doppler-taajuuksia ja päättelee kohteen nopeuden palautuvasta säteilystä. Kuvaa tuottavasta tekniikasta yleinen käyttökohde on sijainnin havainnoiva tutka, jota käytetään laajalti mm. sään ennustamiseen tai lentoliikenteen valvontaan. Luonnonvarojen tarkkailuun kehitetyt lentokonetutkat saivat alkunsa sotilaskäytöstä 1940-luvulla. Sotilaskäytössä tutkat ovat merkittävässä roolissa lentävien uhkien, kuten ohjusten ja vihollisen lentoliikenteen havainnoinnissa. Laivaliikenteessä tutkat avustavat rannikonmuotojen, ahtaiden kanavien ja muiden vesilläliikkujien havainnoinnissa huonossakin kelissä (vedenpinnan yläpuolella). Siviili- ja sotilaskäytön sovellutuksilla on paljon eroavaisuuksia ja niiden kehityskin meni eri tahtia, kunnes 1960-luvun lopussa suoritettiin

ensimmäinen kaukokartoitusprojekti, joka oli menestys. Kartoituksille oli suuri tarve Etelä-Amerikassa, jossa trooppinen ilmasto aiheuttaa paljon sumua ja pilvisyyttä, mikä estää ilmakuvausten tai vähintäänkin tekee siitä epätarkkaa. Tutkakuvaus tuotti metsien lisäksi arvokasta tietoa myös kaivosmineraaleista, kuljetusmahdollisuuksista, vesivaroista ja potentiaalisista maatalousalueista. Merkittävä kehitysaskel oli tutkateknologian vieminen avaruuteen 1970-luvun lopussa. Ensimmäisen satelliitin laukaisun jälkeen vauhti on kiihtynyt, kun valtiot ovat luoneet tutkien kehittämiseen omia ohjelmia ja yksityiset yritykset ovat tulleet mukaan kaupallisen potentiaalin myötä. (Lillesand ym. 2004).

1.2.2 Sivuttain kuvaava tutka

Tutkimuksessa käytetty torniin kiinnitetyn sivuttain kuvaavan tutkan (Side-looking radar system = SLR) toiminta perustuu erittäin lyhyisiin ja energiatiheisiin pulsseihin, joita lähetetään kohteen suuntaan. SAR-sensorilla kuvataan aina nadiirista katsottuna viistosti, koska muuten takaisin sironneita säteitä ei pystytä erottamaan toisistaan. Maan tason resoluutio koostuu pulssin pituudesta ja antennin keilanleveydestä. Pulssin pituus saadaan laskemalla aika, joka antennilla menee lähetetyn pulssin vastaanottamiseen. Siitä voidaan päätellä spatiaalinen resoluutio energian etenemisen suunnassa eli ns. kantamasuunnassa. Pinnan resoluutio saadaan laskemalla kallistusresoluutio, joka perustuu depressiokulmaan. Sen takia kauempana olevien kohteiden resoluutio on pienempi, koska depressiokulma pienenee etäisyyden kasvaessa. Tutkan säteen leveys määrittää resoluution leveyden atsimuutti (=vaakasuunta) suunnassa. Molemmat parametrit kasvavat tutkan ja kohteen välisen etäisyyden mukaan.



Kuva 1.1. Kaavio SAR-menetelmän toimintaperiaatteesta. θ_L = katselukulma, θ_d = depressiokulma, θ_i = säteen kohtauskulma.

1.2.3 Synteettisen apertuurin tutka

Synteettisen apertuurin tutka (SAR) on aktiivinen tutkakuvausmenetelmä ja sillä tarkoitetaan yleisesti ottaen kaikkea siihen liittyvää: laitteistoa, aallonmuotoa, signaalin prosessointia ja kuvanmuodostusta. Yleensä sillä kuitenkin tarkoitetaan tekniikkaa, jolla voidaan jäljitellä yhtä pitkää antennia kuvaamalla pienellä antennilla sarjassa. Peruseriaate on, että fyysinen antenni liikkuu linjaa pitkin (D_{SAR}), jossa se kuvaa leveällä keilalla joko yhtä linjaa jatkuvasti (stripmap-menetelmä) tai kohdistetusti tiettyä pistettä eri paikoista (spotlight-menetelmä) (Visa ym. 2015). Kuvauskohdat muodostavat jonon, jota voidaan käsitellä matemaattisesti yhtenä pitkänä antennina (Lillesand ym. 2004). Kauempana olevat kohteet tulevat kuvatuksi lähellä olevia useammin, joten tehokas kuvaus kasvaa kantaman suhteessa. Menetelmän kehitys alkoi tuottamalla kaksi-dimensioista intensiteettikuvaa real-

beam ground mapping-menetelmällä. Tämä tapahtui yhdistämällä yksi-dimensioisia yhden pulssin kuvia vierekkäin (Richards ym. 2010). Resoluutio koostuu sivuttaissuuntaisesta eli kuvaussuuntaisesta etäisyydestä (cross-range resolution CR) ja tutkan liikesuunnan akselista. Etäisyydelle R ja atsimuuttisuunnan keilanleveydelle x (radiaaneina) CR on arviolta

$$\Delta CR \approx R\theta_3 \quad (1.1).$$

Yksinkertaistettu kaava keilanleveydelle x on

$$\theta_x \approx \frac{\lambda}{D}, \quad (1.2)$$

jossa λ on aallonpituus ja D on antennin pituus. Yhdistämällä kaavat saadaan

$$\Delta CR \approx R \frac{\lambda}{D}, \quad (1.3)$$

jolloin huomataan, että suuret etäisyydet vaativat todellisuudessa erittäin pitkän antennin. Kun mittaukset on suoritettu, ne yhdistetään koherentisti ja lopputuloksena on SAR keilanleveys θ_{SAR} kaavalla

$$\theta_{SAR} \approx \frac{\lambda}{2D_{SAR}} \quad (1.4)$$

Menetelmää voidaan soveltaa kaiken kokoisissa tutkissa, jolloin pitkä antenni voi luoda synteettisesti avaruudesta kuvaavan tutkan. SAR-menetelmän etu on myös etäisyyden kasvaessa tasainen vaakasuuntakulma verrattuna ”oikeaan” isoon tutkaan, jossa kulma kasvaa kauemmas kuvatessa. Molemmissa menetelmissä maantason resoluutio kasvaa etäisyyden mukana (Lillesand ym. 2004).

1.3 Lehtialaindeksi ja biomassa

Lehtialaindeksillä (**Leaf Area Index**) tarkoitetaan kasvillisuuden lehtien toispuolista pinta-alaa maapinta-alaa kohden (Watson 1947). Se on tärkeä tekijä metsän perustuotoksen mallinnuksessa, koska fotosynteesi, haihdutus ja hengitys ovat suoraan riippuvaisia latvuston lehtialaindeksistä. Tuotoksen ohella, sen avulla voidaan arvioida metsän terveyttä ja kehitystä. Koska LAI toimii suorassa vuorovaikutuksessa niin monen tekijän, kuten biomassan, ilmakehän kaasujen ja auringon säteilyn kanssa, se on yksi tärkeimmistä parametreista kasvillisuuden seurannassa, hiilen kierrossa ja ilmastomuutoksen mallinnusprosesseissa.

Puun biomassalla tarkoitetaan yksinkertaistetusti puun painoa, tarkemmin määriteltynä voidaan tarkoittaa kuivapainoa, tuorepainoa tai tilavuutta. Puun biomassasta puhuttaessa tarkoitetaan yleensä kuivapainoa eli orgaanisen aineen yhteismassaa (Repola 2013). Läpi historian mielenkiinto on kohdistunut vain puun runkoon, mutta biomassaa halutaan tietää myös latvasta, neulasista, oksista ja juurista (West 2015). Suhteellisia määriä tarkasteltaessa, biomassaa on eniten neulasissa, oksissa ja juurissa, kun rungossa sitä on massaan nähden vähiten. Osat jaetaan yleensä maan pinnan ylä- (Above Ground Biomass, AGB) ja alapuolisiin (Below Ground Biomass, BGB) osiin. Sen mittaamisesta ja syntymekanismeista halutaan tietää yhä enenevässä määrin, koska luotettavilla biomassatiedoilla on useita potentiaalisia käyttökohteita. Biomassaa syntyy, kun puu yhteyttää fotosynteesissä eli imee ilmasta hiilidioksidia ja auringosta energiaa. Silloin puu myös kasvaa, eli kun biomassan tuotto tiedetään tarkemmin, voidaan puun kasvua mallintaa tarkemmin. Fotosynteesin tarvittava hiilidioksidi on kasvihuonekaasu ja se poistuu prosessin jälkeen ilmasta. Tarkat laskelmat hiilen määrästä ovat erittäin tärkeitä ilmastonmuutokseen liittyvissä malleissa ja metsien hiilitaseisiin liittyvissä laskelmissa. Nykyisin valtioita sitovat sopimukset velvoittavat kasvihuonekaasujen seurantaan, jolloin, esim. Suomen tapauksessa, metsät ovat merkittävässä roolissa. Tarkat määrät biomassasta voi myös avata uusia liiketoimintamahdollisuuksia tai olla hyödyksi nykyisille. Puuta kasvatetaan jonkin verran bioenergiaksi, jonka hinnoittelu perustuu enemmän painoon ja energiatihyteen kuin tilavuuteen (West 2015). Useiden toimijoiden takia, erilaisille mittausmenetelmille on kysyntää. Bioenergiaa hyödyntävät hakkuu- ja kuljetusyrietykset saavat punnittua puutavaran luotettavasti hakkuukoneella, kuljetuksen yhteydessä tai viimeistään tuotantolaitoksella, mutta menetelmä sopii vain hakatulle puutavaralle. Metsässä olevan biomassan arviointi on aivan yhtä tärkeää hiilitase- ja ilmastomallien lisäksi myös metsänhoidonsuunnittelussa, hakkuiden suunnittelussa ja hankintaketjun optimoinnissa. Elävän biomassan määrää arvioidaan matemaattisilla malleilla, joissa parametreiksi annetaan mitattuja puustotunnuksia. Pituuden, läpimitan ja iän lisäksi tarkentavat tiedot latvuston koosta, kuoren paksuudesta, ja kasvupaikasta auttavat saavuttamaan erittäin tarkkoja arvioita biomassan määrästä (muun muassa Repola 2009).

1.4 Tutkat metsien kaukokartoituksessa

Metsien kaukokartoitus onnistuu tutkatekniikalla, mutta menetelmää on alettu hyödyntää vasta viime vuosikymmeninä. Tekniikka on kehittynyt kiihtyvään tahtiin 1990-luvulla alkaneiden satelliittihankkeiden saattamana. ERS-1 ja -2 olivat ESA:n ensimmäiset ympäristön ja luonnonvarojen havainnointiin valmistetut satelliitit, joka laukaistiin vuonna 1991 ja 1995. Näiden kanssa yhteistyössä toimi Japanin avaruusjärjestön kanssa laukaistu JERS-1. Edelläkävijän asemassa toimineet satelliitit soveltuivat tutkimusten mukaan hyvin myös metsän kaukokartoitukseen (Kasischke, E. 1994, Kurvonen, L. ym. 1999 sekä Fransson, J. 1999). C-kanavalla mitannut ERS-1 ja L-kanavalla mitannut JERS-1 pystyivät havainnoimaan boreaalisen metsän maanpäällisen biomassan jopa 5 RMSE-% tarkkuudella. Vuonna 1995 myös Kanada aloitti oman satelliitti mission yhteistyössä NASA:n kanssa. RADARSAT-1 ja vuonna 2007 laukaistu RADARSAT-2 suunniteltiin ERS:n tavoin luonnonilmiöiden ja -varojen kaukokartoitukseen. RADARSAT on suunniteltu erityisesti meren ja jään havainnointiin, mutta myös metsien kaukokartoitus onnistuu kohtalaisella tarkkuudella (Saatchi 2000 ja Rignot 1994). Molemmat satelliitit ovat lopettaneet toimintansa, mutta RADARSAT konstellaatio sai jatkoa 12.6.2019, jolloin laukaistiin kolme uutta satelliittia.

Saksan tutkimus- ja opetusministeriö julkaisi Terra-SAR-X (TSX) mission tieteelliseen ja kaupalliseen käyttöön. Saksan avaruusjärjestö DLR:n ja osittain yksityisen yrityksen rahoittama TSX satelliitti laukaistiin 15.6.2007. Helmikuussa 2018 missioon yhdistettiin vielä espanjalainen PAZ-satelliitti, joka kuvaa myös X-kanavalla. Sen avulla ajallinen kiertoaika lyheni huomattavasti, jolloin sama piste kartoitetaan 4-7 päivän välein. Yhteisesti toimiva tutkimissio tuottaa tietoa parhaimmillaan 1 metrin spatiaalisella resoluutiolla. TSX soveltumista metsien havainnointiin on tutkittu laajalti. Suomessa 2011 toteutetussa tutkimuksessa (Karjalainen, M. et al.) todettiin sen havaitsevan perinteisiä puustoparametreja kuviotasolla kohtalaisen hyvällä tarkkuudella. Parhaimmat tulokset saatiin keskimääräisen pituuden (RMSE- % 14,0) ja läpimitan (RMSE- % 19,7) suhteen. Toisaalta tutkimus tehtiin keväällä, joten vuodenaikaisvaihtelun vaikutusta tarkkuuteen ei tutkittu. Huonoimmillaankin X-kanava havaitsi runkotilavuuden RMSE- % 34 tarkkuudella. Samankaltaisia tuloksia raportoitiin Ruotsista (Persson & Fransson 2014), jossa tutkittiin TSX:n käyttöä pituuden ja maanpäällisen biomassan estimointiin kuviotasolla. X-kanava estimoiti pituuden jopa 10 RMSE- % tarkkuudella ja biomassan 25 – 30 RMSE- %. Samalla todettiin nuorten metsiköiden

mallintamisen olevan hankalampaa kuin varttuneiden. Huomattavasti tarkempaan maanpäällisen biomassan mallinnukseen päästiin Norjassa (Solberg ym. 2010), jossa tutkittiin männyn ja kuusen X-kanavan kartoitusta interferometrisellä X-kanavan SAR-tutkalla.

Sentinel-1A ja 1B ovat Euroopan avaruusjärjestön C-kanavalla kuvaavia SAR-tutkasatelliitteja. 1A laukaistiin 3.4.2014 ja 1B kaksi vuotta myöhemmin. Ne tarjoavat parhaimmillaan 5 metrin spatiaalisen resoluution ja aineisto on vapaasti jaossa kaikille. Sentinel-satelliittien yhdeksi käyttökohteeksi mainitaan metsien havainnointi (ESA 2016) ja tutkimusten perusteella se soveltuu siihen kohtuullisen hyvin. Tomppo ym. (2019) tekemän tutkimuksen perusteella Sentinelin tuottamalla aineistolla voidaan jäljittää lumituhot yli 90 % tarkkuudella Etelä-Suomen boreaalisissa metsissä. Myös vuodenaikojen vaihtelun vaikutusta on tutkittu aikasarjojen avulla. S1 pystyy havaitsemaan kasvukauden alkamisen lehtipuiden silmujen avautumisesta (Proietti ym. 2020).

Ruotsissa toteutetussa X-, C- ja L-kanavien vertailussa (Santoro ym. 2019.), yksikään kanava ei yksin pystynyt mallintamaan kuvion runkotilavuutta tai biomassaa luotettavalla tarkkuudella. Kanavia yhdistelemälläkin tulos oli heikko, runkotilavuuden estimaattien suhteellinen RMSE oli parhaimmillaan 31 – 50 %.

Kaikissa mainituissa tutkimuksissa todetaan, että tarkka maastonmuotoja kuvaava malli (DTM = digital terrain model) on välttämätön pohja tarkoille tutkaan perustuville puustomalleille. Kun tarkka DTM on saatavilla, tutka on erittäin potentiaalinen kaukokartoitusväline varsinkin järeissä metsissä tilavuuden ja biomassan mallinnukseen (Niemi 2013). Saatujen tutkimustulosten perusteella SAR-tutka on selvästi 2D-satelliittikuvia tarkempi menetelmä niin kuviotasolla kuin suuremmilla alueilla.

Kaukokartoitus on käytännössä ainoa tehokas ja toimiva ratkaisu lehtialaindeksin havainnointiin, koska manuaalinen työ on hidasta ja tehotonta eikä täten sovellu sen seurantaan. Kaukokartoitusta on käytetty LAI:n havainnointiin verrattain lyhyen aikaa: ensimmäiset temporaaliset kartat tuotettiin 2000-luvun alussa, kun MODIS-satelliitti aloitti toimintansa NASA:n aloitteesta (Rautiainen 2006). LAI on dynaaminen parametri, joka muuttuu vuodenaikojen ja ilmastonmuutoksen mukaan, joten mittauksia on suoritettava useasti (Manninen 2005.). Perinteisesti sitä on tosin mitattu optisilla kaukokartoitusmetodeilla, koska metsän heijastusspektri on suurimmilta osin peräisin lehden pinnalta. Vaikka menetelmät ovat kehittyneet, ovat optiset menetelmät nykyisinkin melko

epätarkkoja varsinkin havumetsien osalta (Günlü, A. ym. 2017.). Vasta viime vuosina laukaistut satelliitit tuottavat 30 ja 10 m resoluution aineistoa ja kuvaavat punaisen reunan kanavilla. Näistä mm. Landsat-8 ja Sentinel-2 avulla LAI pystytään kartoittamaan kohtalaisen tarkasti (Korhonen ym. 2017). Lisäksi optisilla menetelmillä on omat heikkoutensa, kuten epätarkka aineisto ja vuorokauden ja vuodenaikojen vaihtelusta seuraavat haasteet, kuten pilvisuus ja varjot. Tutkan käyttöä LAI:n ja muiden metsien dynaamisten parametrien kaukokartoituksessa on käytetty melko vähän. Suuremmilla aallonpituuksilla latvusto ei erotu riittävästi ja X-kanavalla tutkimukset ovat painottuneet biomassaan. Kuitenkin, 2-6 cm pituisten aallonpituuskanavien pitäisi soveltua parhaiten latvuston kartoitukseen, koska latvuston kappaleet ovat yleensä suurempia. X- ja C- kanavat ovat siis lähtökohtaisesti kiinnostavimpia. Kappaleen koon lisäksi kosteus ja säteen tulokulma vaikuttaa sirontaan. Mitä enemmän kosteutta kohde sisältää, sitä vahvemman takaisinsironnan se palauttaa (Lillesand 2004). Suomessa tutkimuksia on tehnyt pääasiassa Manninen ym. (2013, 2005). Viimeisimmät tutkimukset ovat osoittaneet C-taajuuskaistan aineiston korreloivan kohtuullisen hyvin lehtialaindeksin kanssa. Kuusen ja männyn estimaattien virheet ovat parhaimmillaan alle 10 % suuruisia ja sekametsien 27 % virhettä voidaan pitää tarkkana. Tuloksien perusteella tutkateknikka toimii vähintäänkin yhtä hyvin kuin optiset menetelmät.

Biomassan estimointiin tutkia on käytetty huomattavasti enemmän ja verrattain pitkään, varsinkin trooppisilla alueilla tulokset ovat olleet hyviä.. Jo 1990-luvulla (Luckman ym. 1993, Imhoff 1997) tehdyssä tutkimuksessa huomattiin tilastollinen riippuvuus L-kanavan takaisinsironnan ja aluellisen biomassan tiheyden välillä. Myöhemmätkin tulokset ovat tukeneet tätä havaintoa. X-kanava pystyy havainnoimaan pieniä biomassamääriä ja L-kanava suurempia. Varsinkin suurten ja homogeenisten metsien kartoitus onnistuu suhteellisen tarkasti. Kartoitettavien alueiden välillä on suuria eroja: P- ja L-kanava soveltuvat parhaiten pohjoisen boreaaliselle vyöhykkeelle, jossa havupuulajit ovat hallitsevia ja biomassaa alhainen (Rauste 1992, 2006 ja Le Toan 1994, Imhoff 1998). Yksittäisten puiden biomassaa ei löydetyn tiedon perusteella ole yritetty tutkia, nykyistenkin satelliittien muutamien metrien resoluutio voi olla vielä liian epätarkka tähän tarkoitukseen.

Uusinta tekniikkaa tutkien kehittämisessä edustaa suomalainen ICEYE, joka toimii yksityisellä rahoituksella. Tammikuussa 2021 mennessä se on onnistunut lähettämään kymmenen kevyttä (alle 100 kg) SAR-satelliittia avaruuteen ja saman vuoden aikana on tavoite laukaista vielä kahdesan uutta satelliittia. Jo laukaistujen satelliittien perusteella se on maailman laajin

satelliittikonstellaatio. Tulevaisuudessa ICEYE suunnittelee useiden kymmenien satelliittien laukaisua. Satelliitit kantavat X-kanavan sensoria 1 x 1 metrin resoluutiolla. 2020-luvulla mission tulisi olla toimintavalmis, mikä tarkoittaa, että jokaisesta maapallon kohdasta on saatavilla alle tunnin vanhaa aineistoa. ICEYE on suunniteltu palvelemaan myös maa- ja metsätalouden kaukokartoitustarpeita (ICEYE Solutions 2021).

1.5 Tutkimuksen tavoite

Tutkimuksen tavoite on tarkastella, kuinka tarkasti SodSAR-takaisinsirontatutka soveltuu männyn lehtialaindeksi ja biomassan kartoitukseen eri vuodenaikoina. Maastosta mittattua aineistoa pyritään selittämään tutkan mittaamilla arvoilla ja luomalla tästä aineistosta tilastollinen regressiomalli. Lopullinen vertailu ja tulosten tarkastelu tapahtuu mallista saatavien määreiden perusteella.

2. MATERIAALIT JA MENETELMÄT

Tutkimus toteutettiin Ilmatieteenlaitoksen Arktisessa Avaruustutkimuskeskuksessa Suomen Lapissa, Sodankylän kunnan alueella, Tähtelässä (67.367 N, 26.629 E) (Kuva 2.1). Tutkimusala on noin 50 m x 50 m kokoinen neliö ja sijoittuu välittömästi tutkittavan alueen etualalle. Alue on kuivaa ja karua mäntymetsää, jossa ei ole suoritettu mitään metsänhoidollisia toimenpiteitä sen jälkeen, kun alue paloi 1940-luvulla (?). Pohjoisen sijainnin takia, lumi peittää maata yleensä lokakuusta toukokuuhun, lumipeitteen ollessa paksuimmillaan noin 80 cm (Leppänen ym. 2018).



Kuva 2.1. Tähtelän sijainti kartalla.


Taulukko 2.1. Yhteenveto puustoaineistosta n = 1035.

	Läpimitta (cm)	Pituus (m)	Tilavuus (dm ³)	Biomassa (kg)
Keskiarvo	9,3	10,5	47,5	25,4
Keskihajonta	3,6	2,2	61,5	30,0

2.1 Lehtialakuvat

Lehtialavalokuvat otettiin Nikon E8800 digitaalikameralla, johon oli kiinnitetty Nikon FC-E9 kalansilmälinssi. Aineisto kerättiin ennen kasvukautta välittömästi lumien lähdettyä 29.5. ja 3.6., kasvukauden jälkeen 14.8. sekä talvella, kun pysyvä lumipeite oli satanut 13.12. Aineiston keräämiseen vaikutti myös se, että kuvauksia pystyy tekemään vain silloin, kun olosuhteet kuvaamiseen olivat suotuisat. Valokuvien onnistuminen vaatii tasaisen taustataivaan, mutta silti suojan suoralta auringonvalolta ylivalottumisen estämiseksi. Kuvauksia varten alalle perustettiin systemaattinen otantaverkosto. Tavoite oli ottaa kuvia 5 metrin välein, jolloin alalle muodostui 10 linjaa, josta kaikista otettiin 11 kuvaa, yhteensä 110 kuvaa. Suurin osa pisteistä on peitteisestä osasta, jossa lehtialaindeksi vaihtelee melko vähän. Vaihtelua aineistoon tuo tutkan etualalla oleva avoin alue sekä tie, jonka reunasta on kymmenen kuvaa. Kamera säädettiin ottamaan joka pisteestä kolme kuvaa eri valotuksilla, jolloin pystyttiin valitsemaan optimaalisin kuva analyysia varten. Kuva-aineisto kerättiin kolme kertaa: keväällä ennen kasvukautta välittömästi lumien sulamisen jälkeen, loppukesästä kasvukauden jälkeen sekä talvella lumiseen aikaan.

Talven aineisto kerättiin samalta alueelta, mutta kuvia kertyi vähemmän kuin kesäkaudelta. Tutkan edustalta kaksi ensimmäistä kuvattavaa riviä jäivät pois, koska lumiseen aikaan alueella tuli välttää liikkumista. Tämä vaikuttaa analyysiin, koska etualan avoimelta alueelta ei otettu kuvia, jolloin mallin vaihtelu pienenee.



Kuva 2.2. Lehtialaindeksin kuvauspisteet punaisilla pisteillä ilmakuvan ja tutkakuvan päällä.

Kuvat analysoitiin Matrix Laboratory -ohjelmistolla (MATLAB), joka on laskentaan tarkoitettu kaupallinen koodikieli (MathWorks 2020.). Perusosan lisäksi analysointiin tarvittiin IMAGE PROCESSING- työkalua. Itse analyysi suoritettiin latvuston estimointiin kehitetyllä koodilla (Heikkinen ja Korhonen 2009), joka erottaa sinisen värikomponentin ja asettaa jokaiselle kuvalle kynnyksarvon Nobis ja Hunziker-algoritmilla (2005). Algoritmi perustuu sellaisen kynnyksarvon hakemiseen, jolla paikallinen kontrasti taivaan ja latvuston reunan välillä on suurimmillaan. Tuloksena saadaan kuva binäärimuodossa, josta pystytään laskemaan lehtialaindeksi LAI-2000 menetelmällä. Ideana on laskea valon läpäisevyys latvuston läpi eri kulmissa. Tässä sovelletaan Beerin lakia (Kaava 2.3)

$$LAI = 2 \int_0^{\pi/2} -\ln(T(\theta)) \cos(\theta) \sin(\theta) d\theta = 2 \int_0^{\pi/2} G(\theta) LAI \sin(\theta) d\theta, \quad (2.3)$$

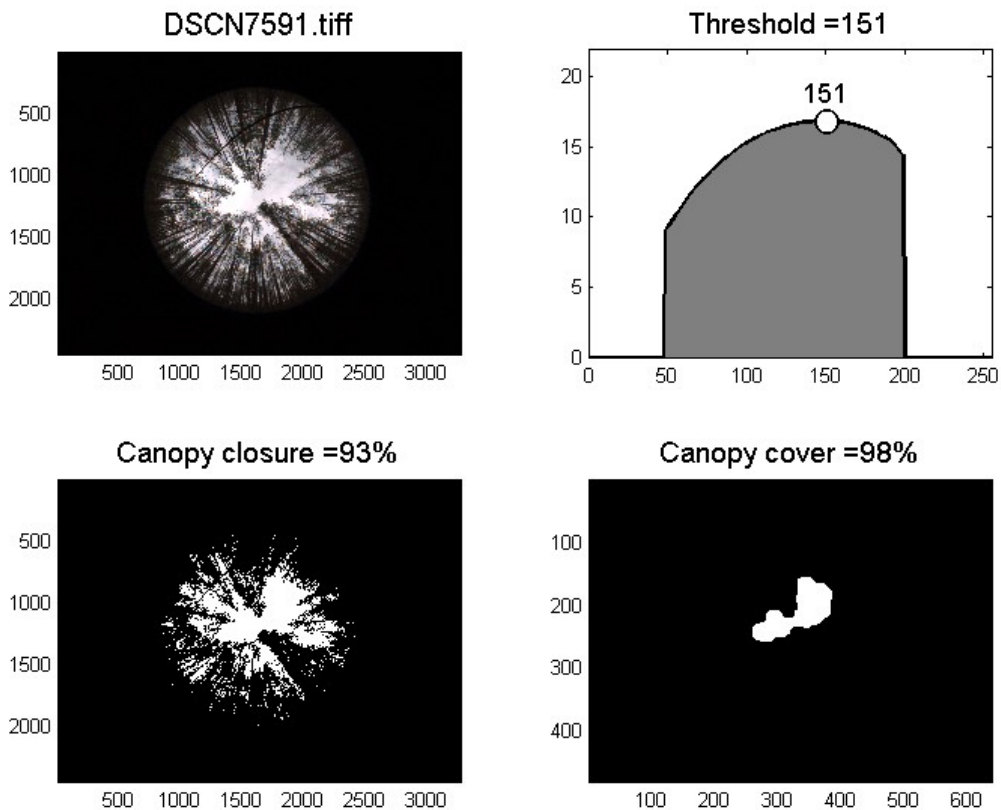
jossa $T(\theta)$ on latvuston reunojen välien osuus auringon zenittikulmassa ja $G(\theta)$ on keskimääräinen heijastuma levästön alueella. LAI-2000 menetelmässä lehtialaindeksin estimaatti lasketaan Millerin integraalilla (Kaava 2.4) summaamalla

$$LAI = 2 \sum_{i=1}^n -\ln(T_i) \cos(\theta_i) w_i \quad (2.4)$$

jossa n on ympyröiden lukumäärä, jolle T_i lasketaan, θ_i on keskimääräinen zenittikulma ympyrälle i ja w_i on painotus tietylle ympyrälle. w_i saadaan laskukaavalla 2.5:


$$w_i = \frac{\sin(\theta_i)}{\sum_{j=1}^n \sin(\theta_j)}. \quad (2.5)$$

Menetelmä on melko luotettava, kun olosuhteet ovat riittävän hyvät eli taivas on tasaisen pilvinen ja luokittelu onnistuu. Merkittävä etu on myös tulosten objektiivisuus, pienempi työmäärä ja yleisesti alhaisempi virhe verrattuna manuaaliseen kynnsarvon hakemiseen.



Kuva 2.3. Esimerkki analysoidusta kuvasta, jossa vasemmalla ylhäällä raakakuva, oikealla ylhäällä algoritmin hakema kynnsarvo, vasemmalla alhaalla optimaalinen ratkaisu, jossa kuva on jaettu binäärisesti tausta-arvoon ja lehtialan määrittävään arvoon, oikealla alhaalla on algoritmin olettama suurimmasta latvusten välisten aukkojen osuudesta.

Lehtialaindeksi on paikkatietoa. Kaikille arvoille määritettiin spatiaalinen sijainti mittaamalla koealaverkoston kulmien sijainti ja siitä laskemalla verkoston pisteiden paikat. Kalansilmälinsillä otettu kuva kattaa puolipallon muotoisen alan, josta itse LAI-arvo lasketaan. Analyysia varten pisteitä piti laajentaa ympyrän muotoon ennen kuin niitä vastaava arvo tutkakuvasta voitiin irrottaa. Sopiva koko ympyrälle löytyy vain kokeilemalla, koska LAI-arvoon vaikuttaa valittu maksimianalysikulma ja puuston pituus. Tässä tutkimuksessa parhaimmat tulokset saavutettiin asettamalla ympyrälle 17-20 metrin säde.



Kuva 2.4. Histogrammit lehtialaindeksimittauksista.

2.2 Puustotiedot ja biomassa

Yksittäisten puiden mittaukset suoritettiin kesäkaudella 2019. Kaikki rinnankorkeusläpimitalta vähintään 5 cm paksut puut identifioitiin ja niistä mitattiin pituus (m), läpimitta (cm) ja vihreän latvuston pituus (cm). Puiden tilavuus on laskettu Laasasenahon (1982) kaavalla käyttäen parametreina läpimittaa ja paksuutta. Lisäksi puiden sijainti tallennettiin RTK-menetelmällä 8 cm ja 5 cm virhemarginaalin sisällä. Koealalta mitattiin yhteensä 1035 runkoa. Biomassa laskettiin yksittäisille puille Repolan (2009) kehittämällä biomassakaavoilla (Kaava 2.1). Biomassa laskettiin puiden kantoläpimitan ja pituuden perusteella.

$$\ln(m_t) = -3.198 + 9.547 \frac{d_k}{d_k+12} + 3.241 \frac{h}{h+20} \quad (2.1)$$

jossa m_t = puun biomassa kilogrammoina, d_k = kannonkorkeusläpimitta (cm) ja h = puun pituus (m). Puista oli mitattu rinnankorkeusläpimitta (1.3 m), joten kannonkorkeusläpimitta

saatiin laskettua kaavasta $d_k = 2 + 1.25 * dbh$. Lisäksi malliin tulee lisätä jäännösvarianssi ($S_e^2 = 0.019$).

Koska kaikille puille oli saatavissa sijainti, pystyttiin mallinnusta kokeilemaan puutasolla. Puiden latvuston säde r annettiin kirjallisuuden perusteella (Muinonen 1995.) (Kaava 2.2).

$$r = (0.945031 + 0.152494 * dbh)/2 \quad (2.2)$$

2.3. Sodankylä Synthetic Aperture Radar

Sodankylä Synthetic Aperture Radar (SodSAR) on yksityisen yrityksen, Harp Technologies, valmistama sivuttain kuvaava takaisinsirontatutka, joka kiinnitettiin ICOS-torniin 21 metrin korkeuteen vuonna 2018 (Kuva 2.5). Laitteisto on suunniteltu erityisesti lumen, maaperän ja kasvillisuuden tutkimiseen.

SodSAR mittaa 1-10 GHz taajuudella ja pystyy lähettämään ja vastaanottamaan neljällä polarisaatiolla (VV, VH, HH, HV). Liikkuminen tapahtuu 5 metriä pitkällä kiskolla ja kolmen eri akselin suuntaisesti. SodSAR suorittaa mittauksia automaattisesti 12 tunnin välein. Tämä mahdollistaa aikasarjan, josta voidaan havaita takaisinsirontan muutoksia (Jorge Ruiz 2020.).


Kanavavalikoima kattaa neljä kanavaa X:stä L-kanavaan (Taulukko 2.2). K_u -alue lisätään päivityksen yhteydessä kaudella 2020-2021, jolloin myös taajuusalue laajenee 18 GHz:iin.

Taulukko 2.2. SodSAR-tutkan kanavat, aallonpituus ja taajuus.

Kanavan tunnus	Aallonpituus (cm)	Taajuus (GHz)
X	2,4 – 3,75	8-12,5
C	3,75 – 7,5	4-8
S	7,5 – 15	2-4
L	15 - 30	1-2



Kuva 2.5. Vasemmalla ICOS-torni kuvattuna maantasolta ja oikealla SodSAR kuvattuna 21 metrin korkeudessa.



Kuva 2.6. SodSAR:in toimintaympäristö sivulta kuvattuna. Ylin katkoviiva kuvaa elevaatiokeilan reunaan, jolla määritetään maksimietäisyys R_{max} . θ_f on antennikeila ja θ_{elev} kuvaa elevaatiokulmaa keilan keskilinjalta mitattuna.

2.3.1 Kuvan muodostaminen

SAR-tutkan keräämästä aineistosta voidaan muodostaa kuva, joka on tarkemmin määriteltynä kaksiulotteinen kohdealueen heijastuvuusjakaumaa kuvaava paikka-avaruuden funktio. Proseduuri voidaan jakaa kahteen osioon: raa'an aineiston keräämiseen ja kerätyn aineiston käsittelyyn. Yleisesti SAR-kuvanmuodostus kuuluu samaan kategoriaan mm. röntgensäteiden tai positroneista muodostetun kuvan kanssa, koska siinä muodostetaan kuva aktiivisesti lähetetystä säteestä. Tutkan erottelukyky etäisyssuunnassa saadaan lähettämällä taajuus- ja vaihemoduloituja pulsseja. Kun pulssit on vastaanotettu, niitä muokataan vastaamaan lyhytkestoista pulssia. Sivuttaissuuntainen erottelukyky koostuu pulssista toiseen muuttuvasta vaihehistoriasta, joka syntyy tutkan ja kohteen välisen suhteen avulla. SAR-kuvan muodostamiseen on kehitetty lukuisia eri algoritmeja ja esittelen niistä muutamia. Menetelmät eroavat yleensä geometrisiltä ja matemaattisilta oletuksiltaan, riippuen siitä onko tavoitteena nopea laskenta, jolloin tuloksena on epätarkempi resoluutio vai raskaampi laskenta yhdistettynä tarkempaan kuvaan. Vanhin ja yksinkertaisin algoritmi kulkee vapaasti suomennettuna nimellä Dopplerin säteen tarkennus (Doppler beam sharpening, DBS). Siinä hyödynnetään Doppler-prosessoitua säteilyä resoluution tarkentamiseen. Kuva on mahdollista tuottaa nopeasti, joten sitä käytetäänkin paljon esim. lentokonekartoituksessa. Kehittyneemmät algoritmit hyödyntävät yleensä kahta eri menetelmää: diskreettiin Fourier-muunnokseen perustuvaa Fast Fourier Transform-algoritmia (FFT) ja täsmällistä aikatason algoritmia (Vehmas 2016.). Merkittävin ero menetelmien välillä on suodatuksissa; FFT-algoritmissa tehdään useita yksinkertaistuksia, kun jälkimmäisessä menetelmässä algoritmi pyrkii ideaaliin suodatukseen. SodSAR:in aineistosta muodostettiin kuva jälkimmäisellä menetelmällä, joka perustuu takaisinprojektio-algoritmiin. Algoritmin käyttö on ollut rajoittunutta, koska se vaatii suurta laskentatehoa. Sillä on kuitenkin merkittävä etu verrattuna frekvenssitason menetelmään; signaalin ei tarvitse tasaisesti jakautunut (Vehmas 2016). Tämä ansiosta tutkalaitteen liikeradan ei tarvitse olla geometrisesti täydellinen ympyrä tai suora, mikä on helpottaa esim. lentokoneella kuvattaessa. Merkittäväksi eduksi voidaan myös lukea se, että luotuun kuvaan voidaan valita koordinaattisysteemi vapaasti. Tällöin SAR-kuva voidaan laskea suoraan digitaalisen korkeusmallin mukaiseen koordinaatistoon.

SodSAR tekniset ominaisuudet

SodSAR:in toiminta perustuu laajaan taajuuspyyhkäisyyn. Etäisyysuunnassa korkea resoluutio saavutetaan vastaanottamalla eri keskitaajuudella lähetetyistä osista signaalia sopivasti näytteitä, ja ottamalla tästä taajuusvasteesta käänteinen Fourier-muunnos. Lopputulos on lähes samalainen kuin lyhyttä, aikakestoltaan $T = 1/B$ pituista pulssia käytettäessä. Resoluutio etäisyysuunnassa saadaan laskettua, kun tiedetään kaistanleveys. Pulssitutkaa käytettäessä voidaan erottaa kohteet, jotka ovat vähintään pulssin aikakestoa T vastaavan etäisyyden $\delta R = cT/2$. Koska SodSAR syntetisoi aikakestoltaan lyhyttä pulssia, etäisyysresoluutio saadaan laskettua kaavalla 2.3.

$$\delta R = \frac{c}{2B} \quad (2.3)$$

Sivuttaissuuntainen resoluutio määräytyy mittauspisteiden ja heijastavan kohteen välisen muutoksen perusteella. Kuvaa muodostettaessa on tärkeää, että kuvattavan kohteen ja tutkan välinen etäisyys muuttuu kahden mittauksen välillä aallonpituuden puolikasta vähemmän, jolloin vaihemuunnos on pienempi kuin 2π . Vaihemuutos kahden peräkkäisen mittauspisteiden y_m ja y_{m+1} välillä on $\Delta\phi = \frac{4\pi\Delta R}{\lambda}$, jossa ΔR on kohteen ja tutkan välinen etäisyysmuutos. Soveltamalla ensimmäisen kertaluvun Taylor-approksimaatiota saadaan johdetuksi lauseke $\Delta R = 2\Delta y \sin \frac{\theta}{2}$, jossa Δy on liikeradan mittausväli. Asettemalla ehdoksi, että kulmasta θ tulevalle kaiulle pätee $\Delta\phi = 2\pi$ sekä korvaamalla kulman θ kohteen ja tutkan kulmamutoksella θ_{SAR} , jos $\theta_{SAR} < \theta$. Sivuttaisresoluutio määräytyy täten lausekkeella

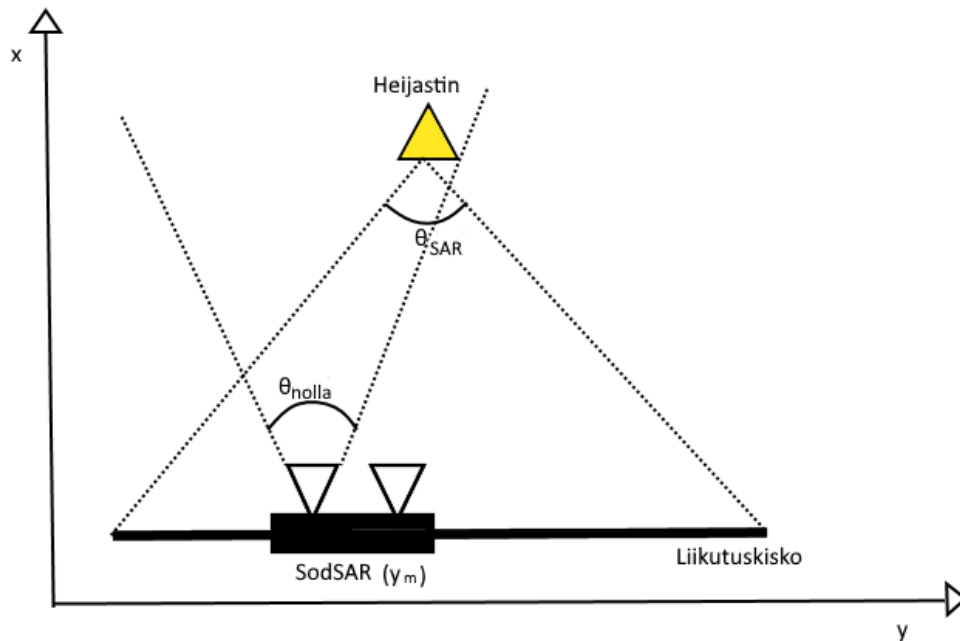
$$\delta y = \frac{\lambda}{4 \sin \frac{\theta_{SAR}}{2}} \quad (2.4)$$

SodSAR:in tapauksessa synteettinen apertuuri on 5 metrin mittainen liikutuskisko, jonka ansiosta tutkan liikerata voidaan olettaa hyvin tunnetuksi. Antennin liikkuessa kiskolla, heijastavan kohteen ja antennin välinen etäisyysmuutos eli vaihehistoria on erilainen. Etäisyys y_m voidaan silti laskea, koska liikerata on tunnettu ja kuvattava alue pysyy paikallaan. Tavoitena on kerätä kustakin kuvapistestä takaisinsironnut energia talteen. Tämä onnistuu sovitetulla suodatuksella, jossa kompensoidaan kaikista apertuurin mittauskohdista tutkan liikkeen vaihemuutos pois, ja tämän jälkeen kaikki eri kohdista tehdyt mittaukset summataan yhteen. Jos kuvattava piste on aiheuttanut takaisinsirontaa, saadaan vaihekorjausten ansiosta

summauksesta samanvaiheisia termejä, jotka vahvistavat toisiaan. Muiden pisteiden heijastus ei vaikuta summaukseen, koska niiden vaihehistoria on erilainen. Sovitettu suodatus jokaiselle kuvapisteelle voidaan ilmaista matemaattisesti (Kaava 2.4).

$$A(x, y, z) = \sum_m \sum_n s_{mn} \exp\left(-i \frac{4\pi f_n R_m(x, y, z)}{c}\right), \quad (2.4)$$

jossa $R_m(x, y, z)$ on kuvapisteen (x, y, z) etäisyys tutkasta apertuurin kohdassa y_m , $A(x, y, z)$ on kompleksinen suure, joka sisältää kuvapisteen (x, y, z) takaisinsironnan ja amplitudin sekä s_{mn} on mitatun kvadratuurinäytteistetyn signaalin näyte taajuudella f_n .



Kuva 2.7. Ylhäältä kuvattu kaavio SodSAR:in mittausgeometriasta. Antennista (y_m) lähtevät katkoviivat kuvaavat tutkan valaisemaa aluetta yhdessä apertuurin kohdassa. θ_{SAR} on kulmasuunnanmuutos, joka määrää sivuttaisresoluution, kun y_m liikkuu kiskoa pitkin.

SodSAR-tutkalla kerätty aineisto prosessoitiin kuvaksi aika-alueen takaisinprojektiio-algoritmeilla. Siinä idea on laskea jokaiselle kuvan solulle (x, y) referenssisignaali ja korreloida sitä tutkan vastaanottamaan signaaliin.


Takaisinprojektiio ottaa huomioon aaltorintaman kaarevan luonteen, mikä on huomattava etu. Sen laskeminen vaatii interpoloinnin, koska erottelusolun (x, y) tarkka etäisyys tutkasta ei

vastaa mitään etäisyysprofiiliin etäisyysnäytettä. Interpolointi olisi tehokkainta tehdä niin, että ensin etäisyysprofiilit ylinäytteistetään etäisyysmuuttujassa r . Yksi tehokas tapa suorittaa ylinäytteistys on nopea Fourier-muunnos (FFT-algoritmi). Siinä signaalin diskreettiin Fourier-muunnokseen lisätään nollia, jolloin aika-alueen signaalin näytteistysvälistä tulee pienempi käänteisen diskreetin Fourier-muunnoksen (IFFT) jälkeen (Vehmas 2016).




Kuva 2.7. Vasemmassa kuvassa alkuperäinen C-kanavan rasteri VV-polarisaatiolla. Oikeassa kuvassa 10 m resoluutioon keskiarvotettu rasteri. Analyysissä käytetyt LAI-pisteet merkattu mustalla. Kuvasajankohta 2.6.2020.

Kesäkuun alun ja heinäkuun lopussa kerättyjen SAR-kuvien dimensiot eroavat toisistaan etäisyys suunnassa. Kevään kuvien koko on 471 x 301, kun loppukesän kuvien koko on 361 x 301. Ero johtuu etäisyysnäytteiden määrästä, joka määritellään kuvien prosessointivaiheessa. Suunta on kaikissa kuvissa sama.




Kuva 2.8. Vasemmassa kuvassa alkuperäinen C-kanavan rasteri VV-polarisaatiolla ja LAI-pisteet punaisella. Oikeassa kuvassa 10 m resoluutioon keskiarvotettu rasteri. Analyysissä käytetyt LAI-pisteet merkattu mustalla. Kuvasajankohta 28.7.2020.



Kuva 2.9. Vasemmassa kuvassa alkuperäinen C-kanavan rasteri VV-polarisaatiolla. Alemmassa 10 m resoluutioon keskiarvotettu rasteri. Analysisissä käytetyt LAI-pisteet merkattu punaisella. Kuvausajankohta 8.12.2020.

Biomassan osalta SAR-kuva keskiarvostettiin yhden metrin rasteriin mean cell weighted average-menetelmällä, kuten LAI-kuvienkin kohdalla. Analyysia varten rasterin arvot irrotettiin käyttämällä puun latvuksen sädettä. Tutkakuvan pienempi rasterikoko on perusteltu, koska yksittäisen puun biomassa on pienipiirteisempi parametri kuin lehtialaindeksi.



Kuva 2.5. Vasemalla C-kanavan tutkakuva 1 metrin resoluutiolla alkukesästä. Oikealla C-kanavan kuva loppukesältä.

2.4 Tilastolliset menetelmät

Tutkan toimivuutta tarkasteltiin regressioanalyysimenetelmällä. Biomassaa ja lehtialaindeksiä yritettiin selittää yksinkertaisen regressioanalyysin avulla. Regressiomallinnus on yleisin

tilastollinen menetelmä empiiristen ongelmien tarkastelussa lähes kaikilla tieteenaloilla (Farheimer 2013). Se jakautuu tarkemmin aineiston perusteella esim. lineaarisiin ja yleisiin lineaarisiin malleihin, sekamalleihin ja ei-parametrisiin malleihin. Yhteistä näille kaikille on se, että niiden avulla yritetään estimoida selitettävää ja riippumatonta muuttujaa y , selittävillä muuttujilla x_1, \dots, x_k . Muuttujaa y voidaan kutsua myös vastemuuttujaksi ja x muuttujia riippumattomiksi muuttujiksi tai syötteeksi. Menetelmän valinta riippuu siitä millaisia muuttujia on tarkoitus käyttää: jatkuvia, kategorisia vai binäärisiä. Regressiomallia kuvastaa se, että muuttujien välinen suhde ei ole deterministinen vaan siinä on nähtävissä satunnaista vaihtelua. Toisin sanoen, selitettävä muuttuja on satunnainen ja tavoite on tutkia, miten selittävä muuttuja vaikuttaa vastemuuttujan odotusarvoon. Tällöin odotusarvo voidaan esittää selittävien muuttujien funktiona $E(y|x_1, \dots, x_k) + \varepsilon = f(x_1, \dots, x_k) + \varepsilon$, jossa ε on satunnainen vaihtelu eli jäännöstermi odotusarvosta.

Kun estimoidaan systemaattista tekijää f aineiston $y_i, x_{i1}, \dots, x_{ik}, i = 1, \dots, n$ avulla, pyritään se analysoimaan erikseen satunnaisesta virhetekijästä ε (Fahrmeir. 2013.).

Kaikista yleisin lineaarisen regression malli on muotoa

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon, \quad (2.5)$$

jossa β_0 on tuntematon vakio eli vakioselittäjän regressiokerroin, β_1 on selittäjän x_1 tuntematon regressiokerroin ja ε on mallin jäännöstermi. Tällöin f :n funktio on lineaarinen siten, että

$$E(y|x_1, \dots, x_k) = f(x_1, \dots, x_k) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon. \quad (2.6)$$

Lineaarinen regressiomalli on erittäin toimiva vaihtoehto tarkasteltaessa jatkuvia muuttujia, kun ne ovat jokseenkin normaalisesti jakautuneita. Oletetaan jäännöstermin odotusarvon olevan 0 eli $E(\varepsilon_i) = 0$, virhearvojen jakautuvan tasaisesti eli niillä on sama varianssi eli $Var(\varepsilon_i) = \delta^2$ ja $Cor(\varepsilon_i, \varepsilon_j) = 0, i \neq j$ eli jäännöstermit ovat korreloimattomia. Tämä tarkoittaa myös sitä, että jäännöstermit ovat riippumattomia. Tuntemattomia parametreja β_0 ja β_1 voidaan estimoida useammalla eri menetelmällä, joista yleisin on pienimmän neliösumman (PNS) menetelmä. Siinä estimoidut $\widehat{\beta}_0$ ja $\widehat{\beta}_1$ arvot saadaan minimoimalla jäännöstermien neliösumma

$$LS(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 = \sum_{i=1}^n \varepsilon_j^2, \quad (2.7)$$

aineistolle $(y_i, x_i), i = 1, \dots, n$. Kun lisätään $\widehat{\beta}_0$ ja $\widehat{\beta}_1$ ehdolliseen keskiarvoon, pätee silloin:

$$\hat{f}(x) = \widehat{\beta}_0 + \widehat{\beta}_1 x. \quad (2.8)$$

Tällöin regressiosuora voidaan käyttää myös y :n ennustamiseen tietylle x :n arvolle, jolloin y :n arvo merkitään $\hat{y} = \widehat{\beta}_0 + \widehat{\beta}_1 x$.

2.4.1 Mallin testaus

Mallin parametreja β voi arvioida tilastollisten testien avulla. Tällöin vaatimuksena on normaalisesti jakautunut jäännöstermi, jolloin pätee myös oletus riippumattomasti ja identtisesti jakautuneista jäännöstermeistä $\varepsilon_i \sim N(0, \delta^2)$. Selitettävän muuttujan arvojen y_i vaihtelua kuvaava kokonaisneliösumma SST kuvaa kokonaisuudessaan mallin selittämää vaihtelua, SSR regressioneliösummaa ja SSE satunnaista jäännösvaihtelua. SST määritellään

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2. \quad (2.9)$$

SSR eli regressioneliösumma muotoa $SSR = \sum_{i=1}^n (x_i' \hat{\beta} - \bar{y})^2$ ja $SSE = \sum_{i=1}^n (y_i - x_i' \hat{\beta})^2$. Näin voidaan laskea selitysaste R^2 , joka kertoo kuinka paljon malli selittää vastemuuttujan vaihtelusta: $R^2 = 1 - \frac{SSE}{SST} = \frac{SSR}{SST}$.

Yksittäisten muuttujien sopivuutta tarkastellaan usein hypoteesien kautta. Nollahypoteesi $H_0 : B_1 = B_2 = \dots = B_k = 0$ on, että mikään kertoimista ei selitä vastemuuttujan hajontaa, jolloin taas vastahypoteesi väittää, että ainakin yksi muuttuja poikkeaa nolasta. Yksittäisen muuttujan merkittävyyttä voidaan testata t-testillä, joka on F-testin erikoistapaus (Fahrmeir, 2013). Nollahypoteesi $H_0 : B_j = 0$ väittää, ettei tuntematon B_j poikkeaa nolasta. R-ohjelmistossa tämä on kuvattu "t-testisuurena", joka voidaan laskea lausekkeesta

$$t_j = \frac{\widehat{B}_j}{se_j}, \quad (2.9)$$

jossa $se_j = \text{Var}(\widehat{B}_j)^{1/2}$ on estimoitu keskihajonta \widehat{B}_j :n virhetermille. t_j on jakautunut $n - p$ vapausasteilla.

Mallin tarkkuuden arvioinnissa tarkasteltiin myös keskineliövirheen neliöjuurta (RMSE, Root Mean Square Error), harhaa ja näiden suhteellisia osuuksia. RMSE ja suhteellinen RMSE saadaan laskettua kaavasta

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (2.10)$$

$$RMSE - \% = 100 * \frac{RMSE}{\hat{y}} \quad . \quad (2.11)$$

Mallin toimivuutta arvioidessa on tärkeää tarkastella myös sirontakuvia. Niistä selviää, miten havaitut ja mallin ennustamat arvot asettuvat sekä miten virhetermit jakautuvat sovitettulla arvoilla. Varsinkin virhetermien kohdalla on tärkeää, että ne jakautuvat tasaisesti kaikkien havaintojen kohdalla.

Tilastolliset menetelmät toteutettiin R-ohjelmistolla (versio 4.0.2). Se on monipuolinen tilastolaskentaan keskittynyt ohjelmointikieli, joka perustuu S-kieleen. R:ää julkaistaan GNU-lisenssin alaisena, mikä tarkoittaa, että kaikki ohjelman koodi on avointa. (The R Foundation. 2020).

3. TULOKSET

3.1. Lehtialaindeksi

Kasvukautta edeltävä aineisto kerättiin touko-kesäkuun taitteessa välittömästi, kun lumet sulivat. Kasvukauden jälkeisestä aineistosta luotujen mallien tulokset näkyvät taulukosta 3.1. Mallissa (Kaava 3.1) LAI:ta mallinnettiin SodSAR:in takaisinsironta-arvoilla VV- ja VH-polarisaatiolla. Alkuperäisen tutkakuvan intensiteetti-arvot keskiarvoistettiin 10 metrin rasteriin, jotka irrotettiin mallin vasteeksi (Kaava 3.1). Rasterisolujen keskiarvoistuksessa käytettiin solujen pinta-alalla painotettua keskiarvoa (cell area weighted mean). Vaihtoehtoisesti kokeiltiin myös bicubical-algoritmia, mutta tulokset eivät olleet yhtä luotettavia.

Takaisinsirontaa kuvattiin tässä tapauksessa lineaarisilla arvoilla. LAI-pisteiden säteeksi määritettiin kokeilemalla, tässä tapauksessa 20m.

$$LAI = \beta_0 + \beta_1 * avg_{scatter} + \varepsilon \quad (3.1)$$

Taulukko. 3.1. Kevään regressiomallien tunnusluvut, keskineliövirheen neliöjuuri ja suhteellinen keskineliövirheen neliöjuuri.

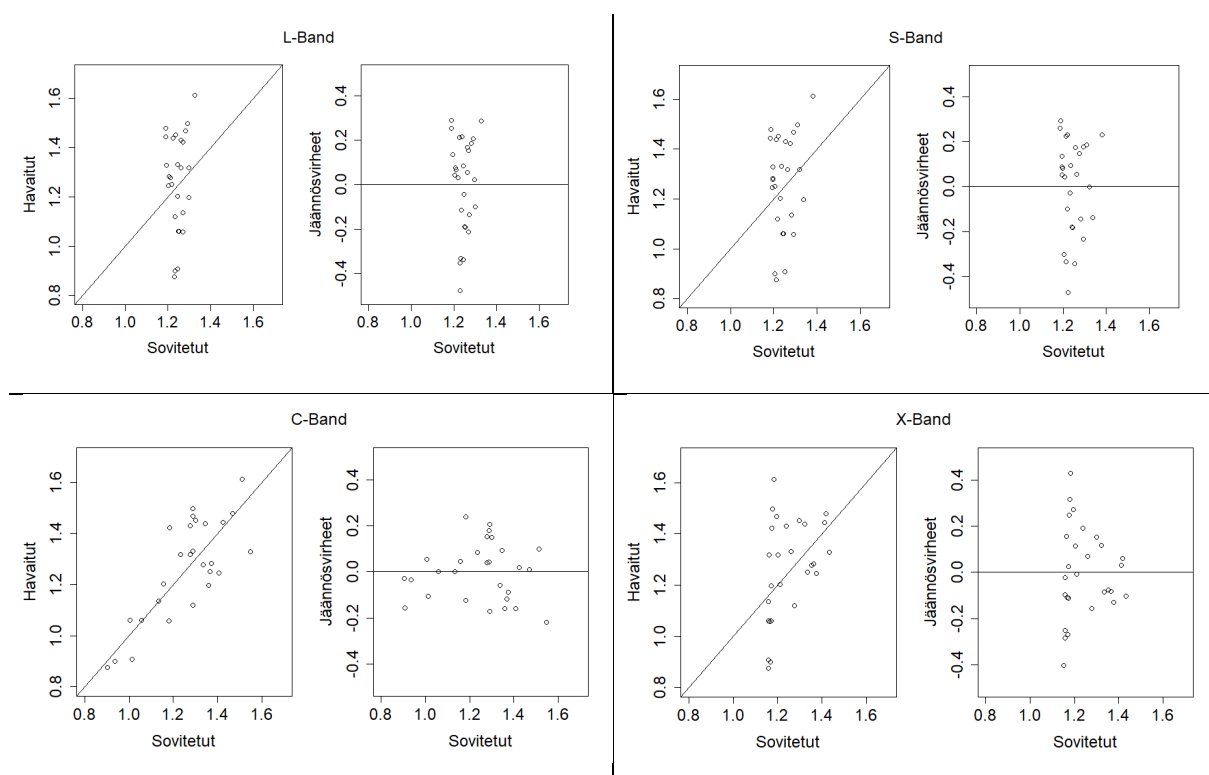
Kanava	Vakiotermi	Kerroin	RMSE	RMSE-%
L	0.63	11.16	0.20	16.3
S	0.69	30.74	0.20	16.0
C	-1.35	314.87	0.13	9.9
X	0.85	105.75	0.20	15.8

Taulukko. 3.2. Kevään regressiomalleista johdetut tilastolliset tunnusluvut.

Kanava	Merkitsevyys (p-arvo)	Selitysaste (R^2)
L	0.1417	0.07
S	0.07862	0.10
C	3.473e-08	0.66
X	0.05298	0.12

Mallien toimivuutta tarkasteltaessa, on syytä katsoa myös sirontakuvia (Kuva 3.1), mistä näkee havaittujen ja mallin ennustamien arvojen jakautumisen. Lisäksi tulee tarkastella residuaalikuvaa, mistä näkee mallin jäännösarvojen jakautumisen sovitetuille arvoille. Hyvin sovitetusta mallista tulisi näkyä lineaarinen riippuvuus havaittujen ja mallin ennustamien arvojen välillä. Jäännösarvojen eli residuaalikuvan osalta optimitilanne on sellainen, jossa jäännösarvot jakautuvat tasaisesti kaikille ennustetuille arvoille.

Tulokset ovat kohtalaisen hyviä ja mukailevat aiempaa kirjallisuutta. C-kanavan selitysaste ja keskineliövirheen neliöjuuri ovat parhaimmalla tasolla. X- ja S-kanavat toimivat merkittävästi heikommin ja L-kanavan kohdalla tilastollinen merkitsevyys on huono. Mallien erot ovat huomattavissa selkeimmin sirontakuvista. C-kanavan malli sovittaa arvot melko tasaisesti havaittujen arvojen kanssa, kun muiden mallien sovitteet osuvat varsin pienelle vaihteluvälille.



Kuva 3.1. Sirontakuvat kevään aineistosta. Vasemman puoleisessa kuvassa y-akselilla havaitut ja x-akselilla mallin ennustamat arvot. Oikean puoleisessa kuvaajassa ennustettujen arvojen jäännösvirheet.

Kasvukauden jälkeinen tutka-aineisto on kerätty heinä-elokuun taitteessa, jonka jälkeen tutka otettiin pois käytöstä päivitystä varten. Tilastollisten mallien tulokset näkyvät taulukosta 3.3. Rasteri käsiteltiin samalla tavalla kuin ensimmäisen aineiston kohdalla. LAI-pisteiden säteeksi määritettiin kokeilemalla 20m.

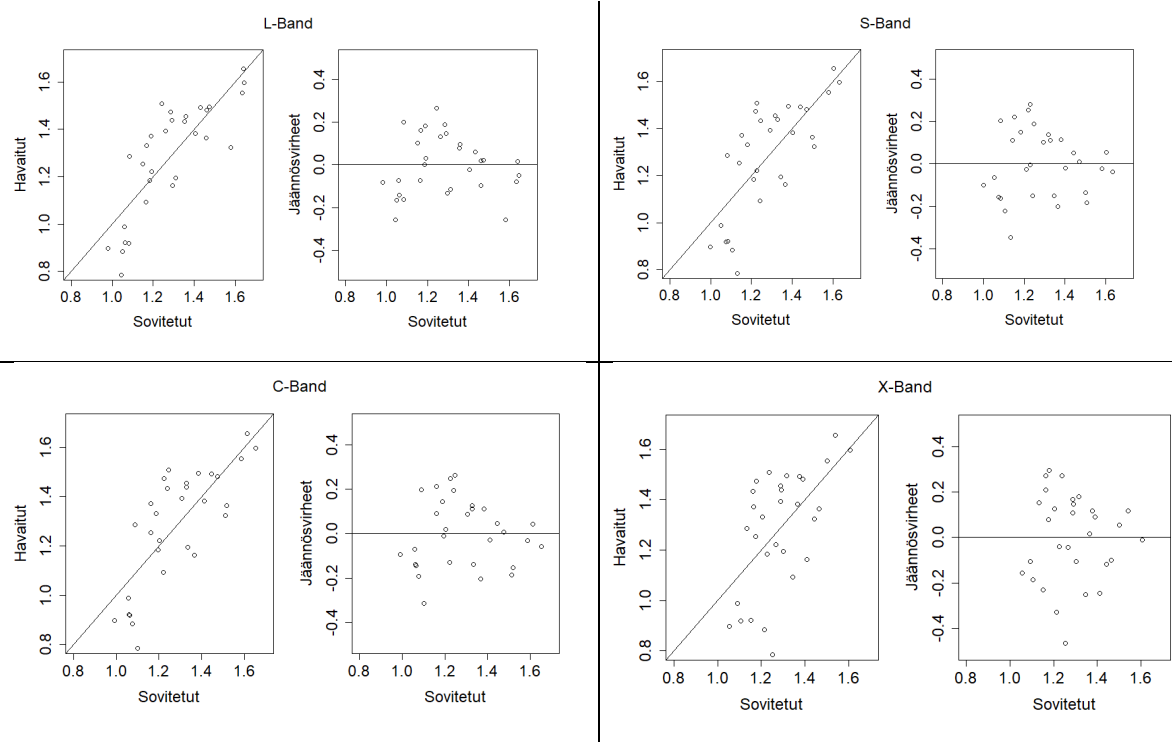
Taulukko. 3.3. Loppukesän aineiston regressiomallien tunnusluvut, keskineliövirheen neliöjuuri ja suhteellinen keskineliövirheen neliöjuuri.

Kanava	Vakiotermi	Kerroin	RMSE	RMSE-%
L	-0.97	35.44	0.14	10.6
S	0.053	66.32	0.16	12.2
C	-0.14	202.74	0.15	11.6
X	-1.63	998.24	0.19	14.7

Taulukko. 3.4. Loppukesän malleista johdetut tilastolliset tunnusluvut.

Kanava	Merkitsevyys (p-arvo)	Selitysaste (R^2)
L	4.972e-08	0.66
S	3.251e-06	0.54
C	7.357e-07	0.59
X	0.0007091	0.34

Heinäkuun lopussa kerätty tutka-aineisto poikkeaa merkittävästi kevään aineistosta. L-, S- ja C-kanavan selitysasteet ovat kaikilla tasaisen korkeat (0,54 – 0,66) (Taulukko 3.4). X-kanava selitysaste on näihin verrattuna huomattavasti alhaisempi, mutta silti korkeampi kuin kevään aineiston kohdalla. Sirontakuvista (Kuva 3.2) eroja on myös haastava huomata, koska kaikilla kanavilla arvot asettuvat hyvin samankaltaisesti. Sovitetut arvot eivät tosin jakaudu kovin tasaisesti: malli ennustaa pienillä arvoilla yliarvioita ja suuremmilla arvoilla aliarvioita. Myös jäännösarvojen osalta eroavaisuuden kanavien välillä näyttäisivät olevan yhtä marginaalisia. Residuaalien vaihteluväli on suurinta pienillä LAI-arvoilla ja vaihtelu pienenee suurempiin arvoihin liikuttaessa.



Kuva 3.2. Sirontakuvat loppukesän aineistosta. Vasemmalla havaitut ja mallin sovitetut arvot sekä oikealla sovitetut arvot ja niiden jäännösarvot.

Taulukko 3.5. Talven regressiomallien tunnusluvut.

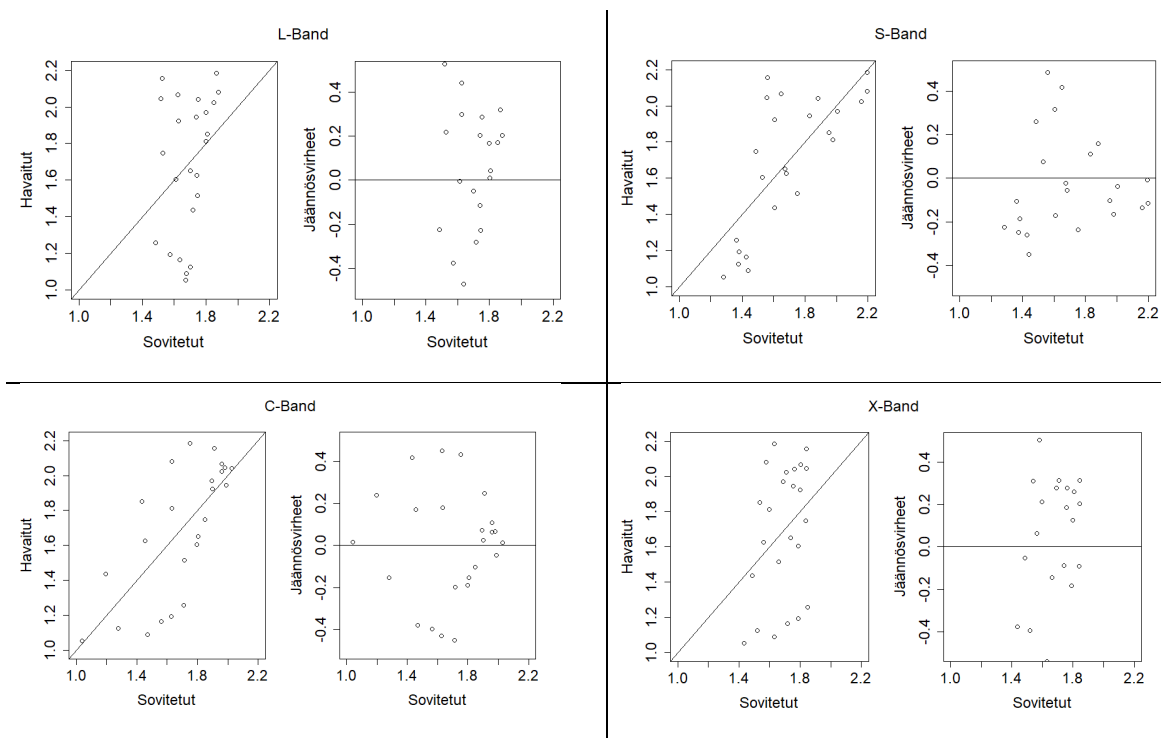
Kanava	Vakiotermi	Kerroin	RMSE	RMSE-%
L	1.15	14.34	0.37	21.63
S	-1.78	278.30	0.27	15.99
C	-2.95	727.35	0.25	15.02
X	0.57	335.51	0.35	20.45

Taulukko 3.6. Talven regressiomallien merkitsevyys ja selitysaste.

Kanava	Merkitsevyys (p-arvo)	Selitysaste (R^2)
L	0.557	0.016
S	0.000256	0.46
C	6.138e-05	0.53
X	0.096	0.12

Talven aineistosta tehtyjen mallien tunnusluvut näkyvät taulukoissa 3.5 ja 3.6. Tulokset ovat talven osalta samassa linjassa kevään tulosten kanssa. C-kanavan tilastollinen merkitsevyys ja selitysaste on parhaimmalla tasolla, mutta kuitenkin hieman heikempi kuin keväällä. S-kanavan selitysaste on hieman alhaisempi, mutta eroa kevään ja syksyn tuloksiin on paljon. L-kanava tulokset ovat heikoimmat ja X-kanava osoittaa vain heikkoa selityskykyä.

Kevään tapaan, tässäkin erot on huomattavissa selkeimmin sirontakuvista (Kuva 3.3). C- ja S-kanavien havaittujen ja sovitettujen arvojen kuvaajilla ei ole merkittävää eroa, mutta jäännösarvojen jakautuminen on erilaista. S-kanavan jäännösarvojen vaihtelu on hieman suurempaa ja C-kanavalla arvot jakautuvat hieman tasaisemmin. Erot ovat joka tapauksessa pieniä.



Kuva 3.3. Sirontakuvat talven aineistosta. Vasemmalla havaitut ja mallin sovitetut arvot sekä oikealla sovitetut arvot ja niiden jäännösarvot.

3.2. Biomassa

Yksittäisen puun biomassan mallintaminen onnistui heikosti. Tutkarasteri keskiarvoistettiin 1 metrin resoluutioon, jolloin myös pienikokoisimmat puut pystyivät erottumaan. Kun aineistona käytettiin kaikkia mitattuja puita tutkan kuvaamalta alueelta, tutkarasterin arvot eivät osoittaneet mitään tilastollista selityskykyä biomassan osalta. Tulokset kuitenkin paranivat huomattavasti, kun aineistoa rajattiin voimakkaasti. Kun analyysistä rajattiin ulos kaikki rinnankorkeudelta alle 12 cm paksut puut, mallinnus onnistui hieman paremmin. Kaikki seuraavaksi esiteltävät tulokset perustuvat rajattuun aineistoon.

Taulukko 3.7. Kevään biomassamallien tunnusluvut.

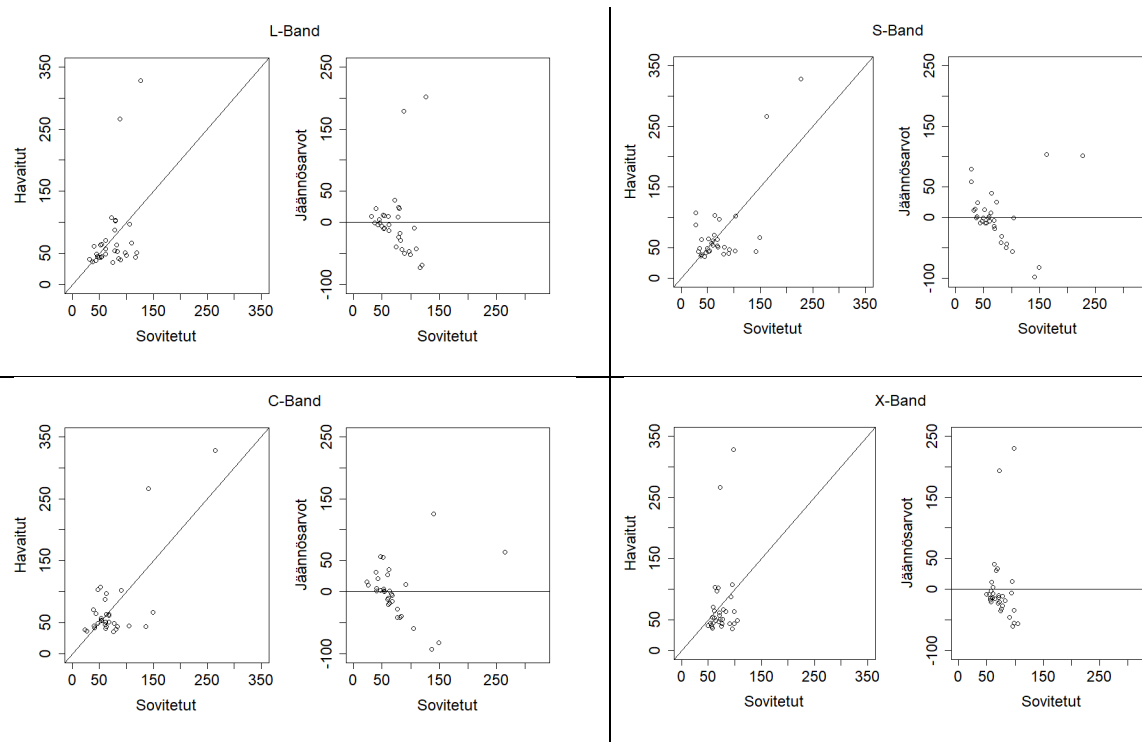
Kanava	Vakiotermi	Kerroin	RMSE	RMSE-%
L	-37.79	1956.64	56.10	76.31
S	-62.76	8425.40	43.92	59.75
C	-74.72	22632.83	41.85	56.94
X	23.83	15450.29	59.63	81.12

Taulukko 3.8. Kevään biomassamallien merkitsevyys ja selitysaste.

Kanava	Merkitsevyys (p-arvo)	Selitysaste (R^2)
L	0.0188	0.17
S	7.849e-06	0.49
C	1.776e-06	0.54
X	0.167	0.06

Kevään osalta C-kanavan selityskyky on parhaimmalla tasolla (0.54) ja S-kanavalla lähes yhtä hyvä (0.49) (Taulukko 3.8). Vastoin ennakkokäsitystä, X-kanavan merkitsevyys ja selitysaste ovat heikoimmalla tasolla. Myöskään L-kanavan tulos ei ole kovin hyvä, mikä toisaalta oli odotettavissa.

Sirontakuvien (Kuva 3.4) muoto on kaikilla kanavilla melko yhtenäinen. Merkittävimmät erot aiheutuvat suurimpien puiden sovitteista. C- ja S- kanavilla mallin tulee vaihtelua, mutta L- ja X- kanavien malli sovittaa kaikki puut samaan kokoluokkaan.



Kuva 3.4. Kevään aineiston regressiomalleista muodostetut kuvaajat, jossa vasemmalla havaitut ja mallin sovitetut arvot sekä oikealla sovitetut arvot ja niiden jäännösarvot.

Taulukko 3.9. Biomassamallien tunnusluvut loppukesältä.

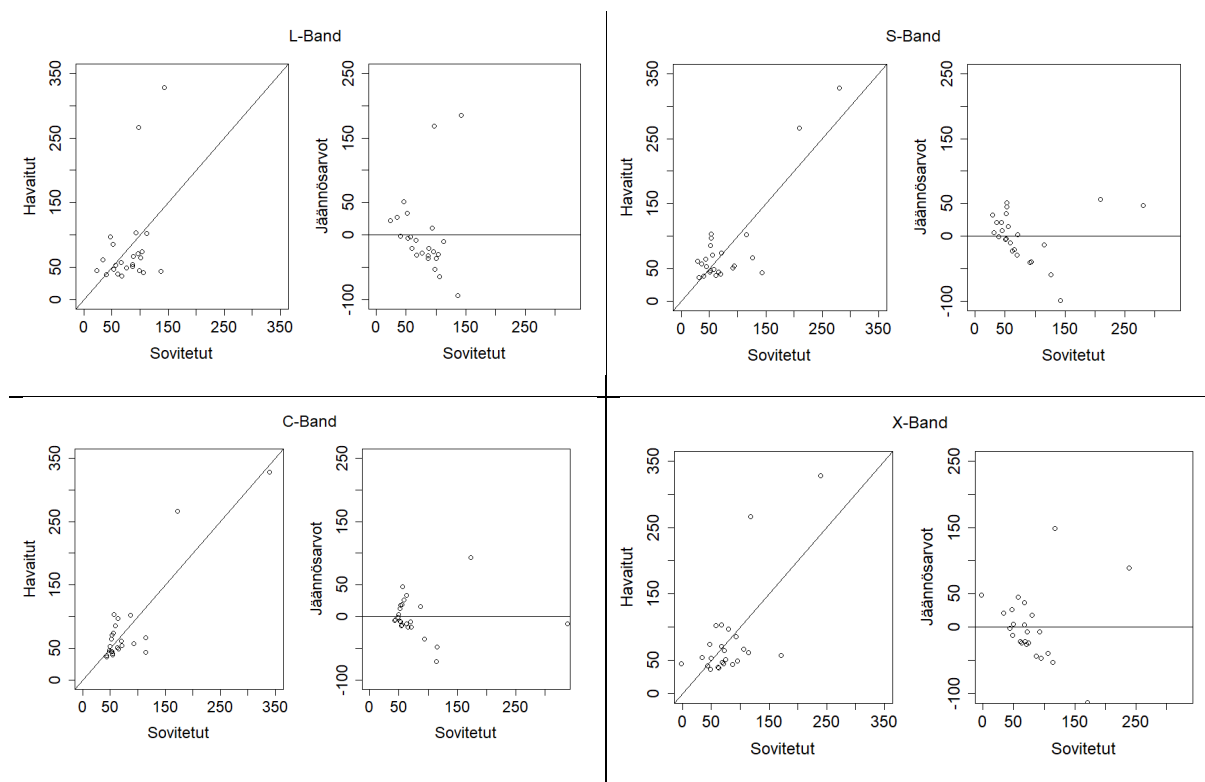
Kanava	Vakiotermi	Kerroin	RMSE	RMSE-%
L	-131.27	5479.68	61.73	76.92
S	-107.82	17449.37	36.62	45.64
C	-92.48	40377.40	31.55	39.31
X	-221.93	139577.64	50.49	62.91

Taulukko 3.10. Biomassamallien merkitsevyys ja selitysaste.

Kanava	Merkitsevyys (p-arvo)	Selitysaste (R^2)
L	0.031	0.19
S	1.878e-07	0.72
C	6.743e-09	0.79
X	0.00027	0.46

Loppukesän tulokset ovat kaikkien kanavien kohdalla parempia kuin kevään tulokset. Tulosten järjestys on muuttunut X-kanavan selitysasteen noustessa huomattavasti ($R^2 = 0.42$) ja L-kanavan tulosten ollessa heikoimmat (p-arvo = 0.031 ja $R^2 = 0.19$). C- ja S-kanavien tulosten välillä on edelleen vain vähän eroa C-kanavan selitysasteen ollessa kuitenkin hieman korkeampi.

Sirontakuvia (Kuva 3.5) tarkasteltaessa, ei tilanne ole merkittävästi muuttunut kevääseen verrattuna. C- ja S-kanavien sovitteet asettuvat hieman tarkemmin linjalle, varsinkin pienempien arvojen kohdalla. Jäännösarvojen vaihtelu on myös pienempää kuin L- ja X-kanavien malleissa.



Kuva 3.4. Regressiomalleista muodostetut kuvaajat, jossa vasemmalla havaitut ja mallin sovitetut arvot sekä oikealla sovitetut arvot ja niiden jäännösarvot.

4. TULOSTEN TARKASTELU

4.1. Lehtialaindeksi

Lehtialaindeksin maastomittaukset eri vuodenaikoina onnistuivat kesäkaudella suunnitellusti. Talven aineistossa havaittu LAI on huomattavasti korkeampi, mikä voi kertoa jonkinlaisesta virheestä. Satelliittihavaintoihin perustuen on huomattu, että LAI kehittyy kasvukauden aikana paraabelin tavoin: välittömästi keväällä se lähtee kasvuun saavuttaen piikin heinä-elokuun aikana, jonka jälkeen se lähtee hienoiseen laskuun johtuen lehtipuiden vaikutuksesta (Rautianen ym. 2012). Piikki saavutetaan erityyppisissä metsissä eri aikaan: sekametsissä eteläisessä Suomessa se on heinäkuun puolella välissä, mutta puhtaissa havupuumetsissä se on lähempänä elokuun puoltaväliä. Pohjoisessa kasvukausi on kuitenkin huomattavasti lyhyempi ja lämpötila alkaa laskea pian yöttömän yön loppumisen jälkeen. Talvella LAI:n havainnointi poikkeaa hieman kesästä (Kuva 2.4), koska lunta on satanut tasaisesti myös puiden päälle, jolloin ainakin pienemmät välit latvustossa ovat peittyneet. Todellinen lehtialaindeksi ei kuitenkaan ole syksyyn verrattuna merkittävästi muuttunut. Seppänen ym. (2017) mukaan talvi saattaa aiheuttaa suurempaa vaihtelua aineistoon. Vaikka tutkimuksen kohteena oleva metsikkö on hoitamaton ja siten erittäin tiheä, tulee aineistoon vaihtelua tutkan etualalla olevasta avoimesta alueesta sekä tien varresta otetuista kuvista. Syvemmällä metsässä vaihtelua vaikuttaisi olevan vain vähän.

Lehtialaindeksin regressiomallinnus SodSAR-tutkan takaisinsirona-arvoilla onnistui kohtalaisen hyvin. C-kanavan malli osoittautui merkitsevyyden ja selityksasteen perusteella parhaimmaksi selittäjäksi. Myös selityksaste 0,66 oli parhaimmalla tasolla ja huomattavasti korkeampi muihin kanaviin verrattuna. Kevään ja talven aineistosta luotujen mallien tulokset seuraavat melko tarkasti hypoteesia, jonka mukaan C-kanavan takaisinsironnan pitäisi olla pääasiassa peräisin puuston latvustosta. Siinä mielessä X-kanavan heikot tulokset ovat tätä käsitystä vastaan.

Loppukesän tulokset ovat kautta linja huomattavasti parempia kuin alkukesän ja talven tulokset. LAI-aineiston ollessa vertailukelpoista, tutkakuvien välillä on eroavaisuuksia, mikä luo vertailulle omat haasteensa. Loppukesän tutkakuvissa etäisyysnäytteiden määrä on alhaisempi (471 vrt. 361), mikä tekee kuvasta etäisyysuunnassa lyhyemmän. Pienempi määrä

vaikuttaisi kuitenkin parantavan tarkkuutta, koska tarkastelu keskittyy tutkan etualalle. Mitä kauemmaksi etäisyys tutkasta kasvaa, sitä enemmän kuvassa on myös kohinaa.

Mallien selitysasteet ovat huomattavasti korkeampia kaikkien kanavien osalta. L-, C- ja S-kanavien malleja voidaan pitää erittäin tarkkoina selitysasteiden ($L = 0.66$, $C = 0.59$ ja $S = 0.54$) puolesta. RMSE- ja RMSE-% arvoja tarkastelemalla huomataan niiden vaihtelevan äärimmäisen vähän, vaikka riippumatta itse mallin selitysasteesta. LAI:n osalta vaihtelua voi siis liian vähän. Sirontakuvia (Kuva 3.2) katsomalla huomaa, että malli ei sovita arvoja tasaisesti. Pienien arvojen osalta mallin sovitteet ovat yliarvioita ja suuremmilla arvoilla taas aliarvioita. Tämä voi osaltaan selittää miksi RMSE-arvot ovat vain hieman suurempia, vaikka mallin merkitsevyys ja selitysaste ovat yhtä hyviä.

Erot alku- ja loppukesän välillä voivat selittyä juurikin pienemmällä kuvalla ja sitä kautta myös pienemmällä aineistolla. Alku- ja loppukesän välillä on myös ympäristön olosuhteista johtuvia eroja, jotka vaikuttavat tutkan vasteeseen. Lumipeite oli talvella 2019-2020 poikkeuksellisen paksu ja lumet sulivat myöhäisessä vaiheessa (0 cm mitattiin Tähtelässä 30.5.2020). Sulamisvesistä johtuen kosteusolosuhteet ovat kuivillakin kasvupaikoilla suotuisat juuri kasvukauden kynnyksellä. Heinä-elokuun vaihteessa puiden primäärikasvu on jo loppunut ja vuoden lämpimin kausi käynnissä, jolloin myös sateita on vähemmän. Tämä luonnollisesti vaikuttaa puun eri osien sisältämään kosteuteen ja niiden heijastuskykyyn.

4.2. Biomassa

Regressiomallien tulokset yksittäisten puiden biomassasta olivat heikkoja. Mallit eivät osoittaneet minkäänlaista tilastollista merkitsevyyttä, kun aineistona käytettiin kaikkia alueelta mitattuja puita. Tämä voi johtua pääosin siitä, että kasvupaikka on kuiva ja karu sekä metsä itsessään on hoitamaton, jolloin puut elävät tiheässä ja kilpailu yksilöiden välillä on kovaa. Kaikki nämä tekijät muokkaavat puista niukkasvuisia, eri kokoisia ja ikäänsä nähden pienikokoisia. Peitteisyys estää kasvussa taantuneiden puiden näkymisen, jolloin yksittäisten puiden on haastava erottua. Myös aiemmissa tutkimuksissa on huovaittu, että varttuneempien metsien kaukokartoitus on helpompaa kuin taimikoiden ja nuorten metsien (Kangas ym. 2017).

Kuitenkin, tulokset muuttuivat, kun puustoaineistosta jätettiin pois kaikki puut, joiden läpimitta on alle 12 cm rinnankorkeudella. Suurimpien puiden takaisinsironta on luonnollisesti vahvempaa ja niitä on kappalemääräisesti vähemmän. Mallin kannalta merkittävin tekijä on muutaman suurimman puun sovitteet. Pienimmät puut osuvat sirontakuviissa kanavasta riippumatta yhteen ryppääseen. Kanavien väliset erot pienempien puiden osalta on nähtävissä selvemmin residuaalikuvista, vaikka niissäkin erot ovat pieniä. Jäännösarvojen vaihtelu on suuri L- ja S- kanavien malleissa riippumatta tutkakuvan ajankohdasta. Toisaalta S- kanavan selitysaste ja merkitsevyys ovat lähes yhtä hyviä kuin parhaimmat tulokset tuottaneella C-kanavalla.

RMSE ja RMSE-% ovat isoja parhaimmissakin malleissa. C-kanavan alle 40 % suhteellinen RMSE loppukesän mallista on tarkin tulos ja sitäkin voidaan pitää korkeintaan kohtalaisen hyvänä. Loppukesän tulokset ovat tässäkin tapauksessa kaikkien mallien osalta parempia verrattuna kevääseen.

Yksittäisten puiden biomassassa vaihtelee suurimpien ja pienempien puiden välillä, mutta malli tarvitsisi enemmän havaintoja näiden ääriarvojen väliltä. Isoja puita ei ole myöskään kappalemääräisesti montaa, jolloin tilastollinen päättely on haastavaa.

5. LÄHTEET

- Antropov, O., Rauste, Y., Häme, T., Praks, J. Polarimetric ALOS PALSAR Time Series in Mapping Biomass of Boreal Forests. *MDPI Remote Sensing* 9: 999. 2017.
- Belenguer-Plomer, M., Tanase, M., Fernandez-Carrillo, A., Chuvieco, E. Burned area detection and mapping using Sentinel-1 backscatter coefficient and thermal anomalies. *Remote Sensing of Environment* 233(22): 2661. 2019.
- Cartus, O., Santoro, M., Wegmüller, U., Rommen, B. Benchmarking the Retrieval of Biomass in Boreal Forests Using P-Band SAR Backscatter with Multi-Temporal C- and L-Band Observations. *MDPI Remote sensing* 11(14): 1695. 2019.
- Desai, M., Jenkins, W. Convolution backprojection image reconstruction for spotlight mode synthetic aperture radar. *IEEE Transactions on Image Processing* 1(4): 505–517. 1992.
- Fahrmeir, L., Kneib, T., Lang, S., Marx, B. *Regression: Models, Methods and Applications*. Springer. 2013.
- Fransson, J., Israelsson, H. Estimation of stem volume in boreal forests using ERS-1 C- and JERS-1 L-band data. *INTERNATIONAL JOURNAL OF REMOTE SENSING* 20(1): 123-137. 1999.
- Günlü, A., Sedat, K., Ercanli, I., Muammer, S., Estimation of leaf area index using WorldView-2 and Aster satellite image: a case study from Turkey. *Environmental Monitoring and Assessment* 189(11): 538. 2017.
- Hojo, A., Takagi, K., Avtar, R., Tadono, T., Futoshi, N. Synthesis of L-Band SAR and Forest Heights Derived from TanDEM-X DEM and 3 Digital Terrain Models for Biomass Mapping. *MDPI Remote Sensing* 12: 349. 2020.
- Imhoff, M. L., Sisk, T.D., Milne, A., Morgan, G., Orr, T. Remotely Sensed Indicators of Habitat Heterogeneity: Use of Synthetic Aperture Radar in Mapping Vegetation Structure and Bird Habitat. *Remote Sensing of Environment* 60: 217-227. 1997.
- Imhoff, M., Carson, S., Johnson, P. A Low-Frequency Radar Experiment for Measuring Vegetation Biomass. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING* 36(6). 1998.

- Jorge Ruiz, J., Vehmas, R., Lemmetyinen, J., Uusitalo, J., Lahtinen, J., Lehtinen, K., Kontu, A., Rautianen, K., Tarvainen, R., Pullainen, J., Praks, J. SodSAR: A Tower-Based 1-10 GHz SAR System for Snow, Soil and Vegetation Studies. *Sensors* 20: 6702. 2020.
- Kangas, A., Astrup, R., Breidenbach, J., Fridman, J., Gobakken, T., Korhonen, K. T., Maltamo, M., Nilsson, M., Nord-Larsen, T., Naesset, E., Olsson, H. Remote sensing and forest inventories in Nordic countries – roadmap for the future. *Scandinavian Journal of Forest Research* 33(4). 2017.
- Karjalainen, M., Kankare, V., Vastaranta, M., Holopainen, M., Hyypä, J. Prediction of plot-level forest variables using TerraSAR-X stereo SAR data. *Remote Sensing of Environment*. 2012.
- Kachischke, E., Bourgeauchavez, L., Christensen, N., Haney, E. Observations on the sensitivity of ERS-1 SAR image intensity to changes in aboveground biomass in young Loblolly-pine forests. *INTERNATIONAL JOURNAL OF REMOTE SENSING* 15(1): 3-16. 1994.
- Korhonen, L., Hadi, Packalen, P., Rautiainen, M. 2017. Comparison of Sentinel-2 and Landsat 8 in estimation of boreal forest canopy cover and leaf area index. *REMOTE SENSING OF ENVIRONMENT* 195: 259-274.
- Korhonen, L. & Heikkinen, J. 2009. Automated analysis of in situ canopy images for the estimation of forest canopy cover. *Forest Science* 55(4): 323-334.
- Korhonen, L. 2020. MATLAB codes for canopy image analysis. (<https://www.mathworks.com/matlabcentral/fileexchange/24314-matlab-codes-for-canopy-image-analysis>). MATLAB Central File Exchange. Retrieved June 12, 2020.
- Kurvonen, L., Pulliainen, J., Hallikainen, M. Retrieval of biomass in boreal forests from multitemporal ERS-1 and JERS-1 SAR images. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING* 37(1): 198-205. 1999.
- Le Toan, T., Floury, N. On the Retrieval of Forest Biomass from SAR Data. *International Journal of Remote Sensing* 15(14): 2777-2796. 1994.
- Lillesand, T., Kiefer, R., W., Chipman, J., *Remote Sensing and Image Interpretation*. Wiley. 2004.

Manninen, T., Stenberg, P., Rautiainen, M., Voipio, P., Smolander, H. Leaf Area Index Estimation of Boreal Forest Using ENVISAT ASAR. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING 43(7): 2627-2635. 2005.

Manninen, T., Stenberg, P., Rautiainen, M., Voipio, P. Leaf Area Index Estimation of Boreal and Subarctic Forest Using VV/HH ENVISAT/ASAR Data of Various Swaths. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING 51(7): 3899-3909. 2013.

Persson, H. J., Fransson, J. E. S. Comparison between TanDEM-X and ALS based estimation of aboveground biomass and tree height in boreal forests. Scandinavian Journal of Forest Research 32(4): 306-319. 2017.

Persson, H., Fransson, J. Forest Variable Estimation Using Radargrammetric Processing of TerraSAR-X Images in Boreal Forest. Remote Sensing 6: 2084-2017. 2014.

Rautiainen, M., Stenberg, P., Möttöus, M., Lehtialaindeksin kaukokartoituksesta. Metsätieteen aikakauskirja. 2006.

Rauste, Y. Techniques for wide-area mapping of forest biomass using radar data. VTT publications 500. 2006.

Repola, J., Lindblad, J., Laitila, J., Latvusmassan ja kantopuun määrän arviointi hakkuukonemittauksessa. Metlan työraportteja 215. 2011.

Rignot, E., Williams, C., Way, J., Viereck, L. Mapping of forest types in Alaskan boreal forest using SAR imaginary. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING 32(5): 1051-1059. 1994.

Saatchi, S., Moghaddam, M. Estimation of crown and stem water content and biomass of boreal forest using polarimetric SAR imaginary. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING 38(2): 697-709. 2000.

Sandberg, G., Ulander, L.M.H., Fransson, J.E.S., Le Toan, T. L- and P-band backscatter intensity for biomass retrieval in hemiboreal forest. Remote Sensing of Environment 115: 2874-2886. 2011.

Santoro, M., Cartus, O., Fransson, J. E. S., Wegmüller, U. Complementary of X-, C-, and L-band SAR Backscatter Observations to Retrieve Forest Stem Volume in Boreal Forests. MDPI Remote Sensing 11: 1563. 2019.

Seppänen, J., Antropov, O., Jagdhuber, T., Hallikainen, M., Heiskanen, J., Praks, J. Improved Characterization of Forest Transmissivity Within the L-MEB Model Using Multisensor SAR Data. IEEE GEOSCIENCE AND REMOTE SENSING LETTERS, VOL. 14(8). 2017.

Solberg, S., Astrup, R., Gobakken, T., Naesset, E., Weydahl, D.J. Estimating spruce and pine biomass with interferometric X-band SAR. Remote Sensing of Environment 114: 2353-2360. 2010.

Tomppo, E., Antropov, O., Praks, J. Boreal Forest Snow Damage Mapping Using Multi-Temporal Sentinel-1 Data. MDPI remote sensing. 2018.

[Verkkolähde] <https://www.iceye.com/solutions/civil/forestry-monitoring>. ICEYE Solutions. Forestry monitoring. 2020.

[Verkkolähde] <https://www.r-project.org/about.html>. 2020. The R Foundation.

Vastaranta, M., Yrttimaa, T., Saarinen, N., Xiaowei, Y., Karjalainen, M., Nurminen, K., Karila, K., Kankare, V., Luoma, V., Pyörälä, J., Junttila, S., Tanhuanpää, T., Kaartinen, H., Kukko, A., Honkavaara, E., Jaakkola, A., Liang, X., Wang, Y., Vaaja, M., Hyyppä, H., Katoh, M., Wulder, M. A., Holopainen, M., Hyyppä, J. Airborne Laser Scanning Outperforms the Alternative 3D Techniques in Capturing Variation in Tree Height and Forest Density in Southern Boreal Forests. Baltic Forestry 28(2): 268-277. 2018.

Vehmas, R. Liikekompensaatio- ja autofokusmenetelmät SAR- ja ISAR-tutkien signaalinkäsittelyssä. Puolustusvoimien tutkimuslaitoksen julkaisuja 3. 2016.

Visa, A., Vehmas, R., Jylhä, J., Väilä, M. Korkean resoluution ja suuren kuva-alueen SAR. Tiivistelmäraportti. Tampereen teknillinen yliopisto, Signaalinkäsittelyn laitos. 2015.

Watson, D., Comparative physiological studies in the growth of field crops. I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years. Annals of Botany 11: 41-76. 1947.

Zhanmang, L., He, B., Quan, X. Potential of texture from SAR tomographic images for forest aboveground biomass estimation. Int J Appl Earth Obs Geoinformation 88. 2020.