

# **Järvivuovikon (*Phragmites australis*) biomassan arviointi Sentinel 2 -satelliittikuvista**

Roosa Väisänen

Maantiede  
pro gradu -tutkielma  
Laajuus: 30 op

Ohjaaja:  
Harri Tolvanen

14.4.2023  
Turku

Pro gradu -tutkielma

**Pääaine:** Maantiede

**Tekijä:** Roosa Väisänen

**Otsikko:** Järviruovikon (*Phragmites australis*) biomassan arviointi Sentinel 2 -satelliittikuvista

**Ohjaaja:** Harri Tolvanen

**Sivumäärä:** 64 sivua + liitteet 2 sivua

**Päivämäärä:** 14.4.2023

---

Järviruoko (*Phragmites australis*) on 1-3 metriä korkea putkilokasveihin kuuluva kasvi, joka tulee toimeen monenlaisissa ympäristöissä. Järviruokoa kasvaa Suomessa muun muassa rannikoilla, matalissa järvissä ja avoimilla vesialueilla. Järviruoko on levinnyt viimeisten vuosikymmenten aikana voimakkaasti. Järviruoko kasvaa laajoina ja tiheinä monokulttuureina. Levitessään järviruoko valtaa tilaa muulta kasvustolta. Ruovikoituminen aiheuttaa vesistöjen umpeenkasvua ja vähentää virkistyskäyttöä. Mädäntyessään ruovikoista vapautuu metaanipäästöjä, joista aiheutuu voimakkaita hajuhaittoja.

Järviruon levinneisyys- ja biomassatiedoista hyötyvät tutkijat, asiantuntijat sekä järviruokoyrittäjät. Tietoa järviruovikoista tarvitaan niin kaupallisista kuin ympäristönhoidollisista syistä. Kestävä järviruon hyödyntäminen on keino ruovikoitumisen estämiseksi, kunhan se tehdään oikea-aikaisesti.

Järviruovikoiden maanpäällisen biomassan (AGB) arviointiin vaikuttaa se, että vaikka ruovikot esiintyvät usein monokulttuureina, ne ovat heterogeenisiä biomassaltaan. Järviruovikoiden kartoittaminen maastotöinä vie paljon aikaa ja resursseja. Kaukokartoitusmenetelmien avulla saadaan tarkkoja ajantasaisia tuloksia, joita voidaan hyödyntää järviruovikoiden biomassan arvioinnissa.

Tutkielmassa selvitettiin, kuinka tarkasti tutkimukseen valituilla menetelmillä ja satelliittikuvilla voidaan selvittää järviruovikon biomassa koko tutkimusalueella Paraisten kaupungin alueella Varsinais-Suomessa. Aineistona tutkielmassa käytettiin Sentinel 2 -satelliittikuvia päiviltä 02.10.2020 ja 30.08.2022. Lisäksi kolmelta tutkimusalueelta leikattiin järviruokoa näyteleikkuita varten. Kassorin ja Rapusvikenin lahdelta näytteet leikattiin 28.10.2020 ja Brattnäsvikenin lahdelta 08.09.2022. Yhteensä biomassatietoja saatiin 14 näyteleikkupisteestä.

Valittu ohjatun luokittelun Random Forest -algoritmi luokitteli järviruovikon Sentinel 2 -satelliittikuvista kohtuullisen tarkasti. Tässä tutkimuksessa tuottajan tarkkuus molemmissa kuvissa oli järviruovikon osalta 85 prosenttia ja käyttäjän tarkkuus 58 ja 68 prosenttia. Useamman selittäjän lineaarinen regressiomalli soveltuu hyvin järviruovikoiden biomassan arviointiin Etelä-Suomen olosuhteissa. Lineaarisen regressiomallin selitysaste 2020 kuvalle oli 47 prosenttia ja 2022 kuvalle 94,5 prosenttia.

Biomassa-arviot olivat lähellä näyteleikkuita. Biomassa-arvion onnistumisprosentti näyteleikkuiden osalta oli 89 prosenttia ja biomassa-arviot ovat linjassa aikaisempien tutkimusten kanssa. Tässä tutkimuksessa järviruon märkäbiomassa vaihteli 4,61-14,3 (t/ha) välillä. Keskimääräinen järviruon märkäbiomassa koko tutkimusalueella lokakuussa 2020 oli 6,6 tonnia per hehtaari. Kassorin lahdella 4,61 tonnia per hehtaari ja Rapusvikenin lahdella 8,14 tonnia per hehtaari. Brattnäsvikenin lahdella vuonna 2022 märkäbiomassaa oli 14,3 tonnia per hehtaari.

Tulevaisuudessa olisi tärkeää tutkia ruovikoiden biomassan vuodenaikaisuutta sekä biomassan muutosta. Myös muiden algoritmien ja tarkempien satelliitti -tai dronekuvien tarkastelu on tärkeää, jotta löydetään paras mahdollinen menetelmä ruovikoiden kaukokartoitukseen.

---

**Avainsanat:** Järviruoko, biomassa, Sentinel-2, random forest, lineaarinen regressio

Master's thesis

**Subject:** Geography

**Author:** Roosa Väisänen

**Title:** Estimating common reed (*Phragmites australis*) biomass from Sentinel 2 -satellite imagery

**Supervisor:** Harri Tolvanen

**Number of pages:** 66 pages

**Date:** 14.4.2023

---

Common reed (*Phragmites australis*) is 1-3-meter-tall halophyte, which belongs to the vascular plant family, which can grow in a wide variety of environments. Common reed grows in Finland, for example, on coasts, in shallow lakes and open water areas. Common reed has spread strongly during the last decades. Common reed grows in large and dense monocultures. When common reed spreads it takes up space from other plants. The spreading of reed causes overgrowth of waterways and reduces recreational use. When reeds rot, methane emissions are released, which causes strong odors.

Researchers, experts, and reed entrepreneurs benefit from information on the distribution and biomass of common reed. Information about common reeds is needed for both commercial and environmental reasons. Sustainable utilization of common reed is a way to prevent the spreading of reed, as long as it is done at the correct time.

The above-ground biomass (AGB) assessment of common reeds is influenced by the fact that although reeds often occur as monocultures, they are heterogeneous in their biomass. Mapping reed beds takes a lot of time, resources, and fieldwork. With the help of remote sensing methods, accurate up-to-date results can be obtained, which can be used in the assessment of the biomass of reed beds.

In the study, it was found out how accurately the biomass of common reeds can be determined with the methods and satellite images chosen for the study in the entire study area of the Parainen town in Southwest Finland. Sentinel 2 satellite images from 02.10.2020 and 30.08.2022 were used as data in the thesis. In addition, common reeds were cut from three study areas for sample cuttings. Samples from Kassor and Rapusviken bays were cut on 28.10.2020 and from Brattnäsviken bay on 08.09.2022. In total, biomass data were obtained from 14 sample points.

The selected Random Forest algorithm of supervised classification classified the common reed from the Sentinel 2 satellite images quite accurately. In this study, the producer's accuracy in both images was 85 percent and the user's accuracy were 75 and 58 percent, respectively. The linear regression model of several exponents is well suited for the assessment of the biomass of common reed biomass under the conditions of Southern Finland. The degree of explanation of the linear regression model for the 2020 image was 47 percent and 94.5 percent for the 2022 image.

Biomass estimates were close to sample cuts. The success rate of the biomass estimation for the samples was 89 percent and the biomass estimations are in line with previous studies. In this study, the wet biomass of common reed varied between 4.61-14.3 (t/ha). The average wet biomass of common reed in the entire study area in October 2020 was 6.6 tons per hectare. In the bay of Kassor 4.61 tons per hectare and in the bay of Rapusviken 8.14 tons per hectare. In Brattnäsviken bay in 2022, 14.3 tons per hectare.

In the future, it would be important to study the seasonality of reed biomass and the change in biomass. Examining other algorithms and more accurate satellite or drone images is also important in order to find the best possible method for remote mapping of reed beds.

---

**Key words:** Common reed, biomass, Sentinel 2, random forest, linear regression

# Sisällysluettelo

<b>1</b>	<b>Johdanto</b>	<b>5</b>
<b>2</b>	<b>Järviruovikon kartoitus</b>	<b>8</b>
<b>2.1</b>	<b>Järviruo'on yleiskuvaus</b>	<b>8</b>
2.1.1	Järviruooko lajina	8
2.1.2	Ruovikko biotooppina	10
2.1.3	Ruovikon ravinnekierto	11
2.1.4	Ruovikoituminen	12
2.1.5	Ruovikkoluokittelu	13
<b>2.2</b>	<b>Kasvillisuuden kaukokartoitus</b>	<b>15</b>
2.2.1	Kasvillisuuden kaukokartoituksen tavoitteet	15
2.2.2	Kosteikoiden kaukokartoitus	16
2.2.3	Järviruo'on kaukokartoitus	17
<b>3</b>	<b>Tutkimusalue</b>	<b>20</b>
<b>4</b>	<b>Aineistot ja menetelmät</b>	<b>25</b>
<b>4.1</b>	<b>Aineistot</b>	<b>25</b>
4.1.1	Satelliittikuva-aineistot	25
4.1.2	Biomassa-aineistot	26
<b>4.2</b>	<b>Menetelmät</b>	<b>29</b>
4.2.1	Satelliittikuvamenetelmät	29
4.2.2	Tilastolliset menetelmät	34
<b>5</b>	<b>Tulokset</b>	<b>36</b>
<b>5.1</b>	<b>Näyteleikkuut</b>	<b>36</b>
<b>5.2</b>	<b>Ruovikoiden erottaminen satelliittikuvista ohjatulla luokittelulla</b>	<b>38</b>
<b>5.3</b>	<b>Ruovikon biomassan arviointi</b>	<b>43</b>
<b>5.4</b>	<b>Biomassan alueellinen jakauma</b>	<b>45</b>
<b>6</b>	<b>Pohdinta</b>	<b>50</b>
<b>6.1</b>	<b>Biomassan arviointi satelliittikuvista</b>	<b>50</b>
<b>6.2</b>	<b>Epävarmuustekijät</b>	<b>53</b>
<b>6.3</b>	<b>Jatkotutkimusideat</b>	<b>56</b>
<b>7</b>	<b>Johtopäätökset</b>	<b>58</b>
	<b>Kiitokset</b>	<b>59</b>
	<b>Lähteet</b>	<b>60</b>
	<b>Liitteet</b>	<b>65</b>
	<b>Liite 1 Spearmanin korrelaatiokertoimet, Sentinel 2 -satelliittikuva 02.10.2020</b>	<b>65</b>
	<b>Liite 2 Spearmanin korrelaatiokertoimet, Sentinel 2 -satelliittikuva 30.08.2022</b>	<b>66</b>

# 1 Johdanto

Kosteikkokasvit, kuten järviruoko (*Phragmites australis*) ovat indikaattoreita kosteikoiden tilasta (Zhao ym. 2022). Kosteikoiden kartoitus on tärkeää, sillä arviolta suurimman osan tila on heikentynyt viime vuosikymmenten aikana niin Suomessa, kuin maailmalla (Juvonen & Kurikka 2016). Tietoa järviruovikoista tarvitaan niin kaupallisista kuin ympäristönhoidollisista syistä, kuten rehevöitymisen ja vesistöjen umpeenkasvun vähentämiksi. Kosteikot on määritelty Yhdistyneiden Kansakuntien 2030 agendassa ekosysteemiksi, joka tukee kestävä kehityksen tavoitteiden toteutumista (Thamaga ym. 2021).

Järviruovikon levinneisyys- ja biomassatiedoista hyötyvät tutkijat, asiantuntijat sekä järviruokoyrittäjät. Järviruo'on käyttö ei viime vuosikymmeninä ole ollut suosittua Suomessa, mutta ilmastonmuutos ja tämänhetkinen energiakriisi ovat saaneet yrittäjät ja tutkijat etsimään vaihtoehtoisia ekologisempia energiamuotoja ja kestävä järviruo'on hyödyntäminen on Suomessa käynnistymässä. (Alijoki 2013).

Aikaisemmin ruokoa on Suomessa ja maailmalla käytetty karjan rehuna, rakennusmateriaalina ja käsitöissä. Suomessa karjan rehuna ruokoa käytettiin 1950-luvulle asti, jonka jälkeen sen käyttö on vähentynyt huomattavasti. Ruo'on hyödyntäminen muihinkin käyttötarkoituksiin väheni rehukäytön loputtua (Alijoki 2013). Muualla Euroopassa järviruo'on käyttö ei ole vähentynyt vaan sitä käytetään nykyäänkin paljon rakennusmateriaalina ja sen käyttö on lisääntynyt viimeisten vuosikymmenien aikana. Esimerkiksi Alankomaissa, Virossa ja Latviassa rakennetaan jatkuvasti lisää ruokokattoisia taloja. Tanskassa on jopa 42 000 ruokokattoista taloa (Ikonen & Hagelberg 2007a).

Nopeasti kasvava järviruoko on ekologinen vaihtoehto esimerkiksi energiateollisuuden biopolttoaineeksi. sillä oikein niitettynä ruovikot kasvavat seuraavalla kasvukaudella uudestaan. Ruovikoihin liittyy paljon muitakin liiketoimintamahdollisuuksia, kuten niiden käyttö lannoitteena, biokaasuna tai biohiilenä (Alijoki 2013). Järviruokoa voidaan hyödyntää myös karjan rehuna, kasvualustoina, rakennusten eristeenä sekä kattorakenteissa.

Valtioneuvoston vuosille 2022-2027 laaditussa merenhoitosuunnitelman toimenpideohjelmassa on suunniteltu toimenpiteitä, joilla voidaan parantaa meriympäristön tila. Toimenpideohjelma sisältää muun muassa toimenpiteen, jossa pyritään poistamaan järviruokoa, jotta monimuotoisuus lisääntyisi ja elinympäristöt parantuisivat (Laamanen ym.

2021). Ohjelmassa etsitään kunnostuskohteita, jossa järviruokoa leikkaamalla olisi positiivinen vaikutus aineksen pidättämiseen ja luonnon monimuotoisuuden ylläpitämiseen (Laamanen ym. 2021). Suomen lisäksi myös maailmalla on kiinnostusta uusien alueellisesti selkeiden ja järkevien työkalujen kehittämiseen kosteikoiden tilan ja biomassan arvioimiseksi (Thamaga ym. 2021).

Ruovikoiden korjuun ongelmana on kuitenkin sen taloudellinen kannattavuus. Muita esteitä on aiemmin ollut tietämättömyys ja alan toimijoiden määrä (Alijoki 2013).

Järviruokoliiketoimintaa ovat Suomessa lisänneet kasvaneet hyötykäyttömahdollisuudet sekä vesialueiden omistajien halukkuus vähentää järviruokoa omistamillaan vesialueilla.

Järviruokoliiketoimintaa edistäisi entisestään, jos järviruovikon korjuulle myönnettäisiin taloudellisia tukia (Alijoki 2013).

Hyötykäytön lisäksi ruovikoiden poistosta hyötyvät sekä linnusto että kalakannat, sillä niiden runsaus lisääntyy mosaiikkimaisiksi leikatuissa ruovikoissa (Laamanen ym. 2021). Leikkuu vähentää myös ravinteita vesistöissä. ELY-keskuksen (2022) mukaan ruovikoista voidaan loppukesällä toteutetuilla leikkuilla poistaa yhtä kuiva-ainetonnia kohden paljon ravinteita, arviolta noin 1-2 kiloa fosforia ja 10-20 kiloa typpeä. Mikäli ruovikko leikattaisiin saman kesän aikana kahdesti olisi vastaa määrä 1,5-kertainen (Leikkuun hyödyt 2022). Yhden hehtaarin leikkuulla voitaisiin poistaa 5-10 kiloa fosforia ja 50-100 kiloa typpeä, sillä keskimääräisesti ruovikko tuottaa noin 5 tonnia per hehtaari (Leikkuun hyödyt 2022).

Rannikkokosteikoiden, kuten järviruovikoiden biomassassa on tärkeä kosteikoiden tuottavuuden, terveyden ja ilmastonmuutoksen alttiuden indikaattori. Mahdollisuutta arvioida järviruovikoiden maanpäällistä biomassaa (*above ground biomass*) merkityksellisessä mittakaavassa vaikeuttaa järviruovikon kasvillisuuden luontainen alueellinen vaihtelu. Kaukokartoitus tarjoaa lähestymistavan ruovikoiden biomassan kartoittamiseen (Doughty ym. 2021; Zhao ym. 2022).

Tutkielman tavoitteena on selvittää, kuinka tarkasti tutkimukseen valituilla menetelmillä ja satelliittikuvilla voidaan selvittää järviruovikon biomassaa koko tutkimusalueella.

Osatavoitteena on selvittää järviruovikon levinneisyys tutkimusalueella. Biomassa kuvaa elollisen aineen määrää tietyn pinta-alan alueella. Se voidaan ilmoittaa sekä tuore- että kuivabiomassana. Tässä tutkimuksessa biomassalla tarkoitetaan järviruovikon vedenpäällistä biomassaa. Kasvillisuuden biomassassa vaikuttaa muun muassa sen heijastusarvoihin (Gilmore

ym. 2008). Heijastusarvojen perusteella voidaan arvioida eri kasvuvaiheessa olevat järviruokokasvustot ja niiden biomassa.

Tutkimuskysymyksiin ja tavoitteisiin vastataan tarkastelemalla European Space Agencyn ilmaisia Sentinel 2 -satelliittikuvia, jotka luokitellaan kirjallisuuden perusteella valitulla ohjatun luokittelun menetelmällä. Ohjatun luokittelun jälkeen järviruokopikseille tehdään usean selittäjän lineaarinen regressioanalyysi biomassan selvittämiseksi.

Sentinel 2 -satelliittikuvasta voidaan luokitella hyvin kosteikkoekosysteemit, joilla on korkea erottumiskyky muusta maanpeitteestä (Stratoulis ym. 2015). Järviruoko erottuu kuvan heijastusarvoista parhaiten loppukesän ja syksyn kuvista, joita tässäkin tutkimuksessa on käytetty.

Tutkimuskysymykset ovat:

1. Soveltuvatko tutkimukseen valitut kaukokartoitusaineisto- ja menetelmät järviruovikon levinneisyyden arviointiin?
2. Kuinka luotettavasti regressioanalyysi arvioi järviruovikon biomassan tutkimusalueilla?
3. Kuinka suuri järviruovikon biomassa on tutkimusalueilla?

## 2 Järviruovikon kartoitus

### 2.1 Järviruo'on yleiskuvaus

#### 2.1.1 Järviruoko lajina

Järviruoko (*Phragmites australis*) on 1-3 metriä korkea putkilokasveihin kuuluva kasvi. Suomen rannikoilla järviruoko voi kasvaa jopa neljän metrin korkuiseksi. Järviruoko tulee toimeen monenlaisissa ympäristöissä, niin vesistöjen lähellä, kuin kuivallakin maalla, kunhan ruovikon juurakko on märässä maaperässä (Huhta 2008). Järviruokoa kasvaa rannikoilla, matalissa järvissä, vuorovesirannikoilla, avoimilla vesialueilla, sekä avosoilla (Ikonen & Hagelberg 2007b). Järviruoko ei ole riippuvainen muista lajeista, mutta monet lintu- ja kalalajit ovat riippuvaisia ruovikoista.

Itämeren rannoilla järviruoko on kotoperäinen kasvi, mutta esimerkiksi Pohjois-Amerikassa se on vieraslaji, joka on päätenyt sinne laivojen painolastiveden mukana (Rupasinghe & Chow-Fraser 2019). Suomessa järviruoko on elinvoimainen kasvi, mutta muualla Euroopassa on paikoitellen havaittu ruovikoiden taantumista. Järviruoko on luokiteltu yhdeksi lajiksi, mutta se sisältää kolme alamuotoa (Milke ym. 2020).

Järviruoko on tuulipölytteinen kasvi, joka kukkii loppukeväästä pohjoisessa. Järviruo'on siemenet kuitenkin itävät vasta keskitalvella. Siemenistä itää vain noin 3-44 prosenttia, mutta niiden itävyyspotentiaali säilyy noin vuoden ajan (Huhta 2008). Kun järviruoko on kukkinut, sen korsi kovenee, korren lehdet putoaa ja korsi jää pystyyn talven ajaksi. Jäiden sulamisen jälkeen aallot kasaavat edellisvuoden korret rantaan, mutta toisinaan osa näistä korsista selviää vielä seuraavan kasvukauden yli.

Järviruovikot, joita kansankielellä kutsutaan usein myös kaislikoiksi, valtaavat tilaa muilta kasveilta ja ruovikot ovat levinneet arvokkaille rannikkoalueille ympäri Itämerta. Järviruo'on kasvutahti on noin 4 cm päivässä kasvukaudella kesällä (Tuominen & Lipping 2016).

Ruovikoitumista edistää ihmistoiminnan aiheuttama ravinteiden pääsy vesistöihin. Ravinteita pääsee vesistöihin muun muassa jätevesien ja maatalouden lannoitteiden hajakuormituksesta (Korpinen ym. 2018). Ravinteet aiheuttavat rehevöitymistä, mikä lisää ruovikon biomassan kasvua.

Ruovikon maanpäällinen biomassa on Suomessa suurimmillaan elokuussa (Huhta 2008). Suomessa järviruo'on kuivabiomassa voi parhaimmillaan olla noin 20 tonnia hehtaarilta.



Etelä-Suomessa järviruokoa on arviolta noin 30 000 hehtaaria ja Varsinais-Suomessa yli 15 000 hehtaaria (Pitkänen 2006). Turun ammattikorkeakoulun ja Suomen ympäristökeskuksen Ruovikkostrategia -hankkeen pilottialueilla Etelä-Suomessa järviruo'on kuivabiomassaa havaittiin noin 3-12 tonnia per hehtaari (Ikonen & Hagelberg 2008).

Järviruoko on monipuolinen kasvi, jonka kestävää kortta voidaan hyödyntää monenlaiseen käyttötarkoitukseen. Järviruo'on hyödyntämisessä on muistettava oikea-aikaisuus. Niittäminen on tehtävä linnustolle ja muulle eliöstölle sopivana ajankohtana, erityisesti lintujen pesimisaikojä keväällä on vältettävä (Huhta 2008). Paikoitellen ruovikoiden niittämistä estää se, että osa ruovikoista on erityisesti linnustollisista syistä liitetty kansainväliseen RAMSAR-sopimukseen.

RAMSAR on sopimus, jolla suojellaan biodiversiteetin kannalta tärkeitä kosteikkoalueita eri puolilla maapalloa. Euroopassa RAMSAR-sopimuksella suojeltuja kosteikoita on noin 1400 (Thamaga ym. 2021). Suomessa RAMSAR-listaan kuuluvia kosteikkoja on 49 kappaletta ja näiden alueiden kokonaispinta-ala on noin 785 000 hehtaaria (Juvonen & Kurikka 2016). Suomen luontotyyppien uhanalaisarvioinnin mukaan kosteikkojen tila maassa on huono. Noin puolet Suomen kosteikkotyypeistä on luokiteltu uhanalaisiksi (Juvonen & Kurikka 2016). Kaikki Suomen RAMSAR-alueet kuuluvat myös Natura 2000 -verkostoon.

Järviruo'on niittäminen talvella kaksinkertaistaa tutkimusten mukaan ruokobiomassan määrän seuraavalla kasvukaudella (Huhta 2008). Järviruo'on laatu on myös tasalaatuisempaa, kun se on muutaman kerran leikattu ainakin osittain pois. Alkukesällä tehtävä niitto vähentää biomassaa, mutta ei ravinnepitoisuutta, vaan lisää ravinteita vesistöissä (Huhta 2008). Parhaiten seuraavan vuoden kasvuun vaikuttaa kesällä tehty niitto, mikä vähentää seuraavan vuoden biomassaa. Niiton jälkeistä tilannetta on hankalaa ennakoida, sillä se riippuu pitkälti niittopaikasta. Mikäli järviruovikko halutaan täysin poistaa niitettävältä alueelta, tulee niitto suorittaa veden pinnan alta, mikä estää hapen kulkeutumisen juuristoon. Myös juurakon rikkominen estää järviruo'on kasvun seuraavana vuonna.

## 2.1.2 Ruovikko biotooppina

Järviruoko kasvaa laajoina monokulttuureina eli järviruokojen kanssa harvemmin kasvaa muuta kasvillisuutta. Liejupohjalla järviruokoa on havaittu kasvavan 40-100 kortta neliömetrin alueella, mutta tiheimmillään jopa 300 kortta/m<sup>2</sup> (Huhta 2008). Järviruoko on korsi on halkaisijaltaan noin 4-10 millimetriä (Milke ym. 2020). Ruovikon esiintymiseen vaikuttaa kasvupaikan ravinteisuus, lämpötila, kosteus, pohjan laatu sekä veden korkeus ja virtausolosuhteet. Myös vuosien välisillä sääeroilla on vaikutusta järviruoko kasvuun. Esimerkiksi jäiden väheneminen talvella vaikuttaa positiivisesti järviruoko kasvuun, sillä talvella jäät rikkovat ruokoja ja kasaavat niitä kasaan. (Ikonen & Hagelberg 2008).

Järviruoko on erittäin kilpailukykyinen kasvi, jonka lisääntymistaktiikkaa edistävät sen ominaisuudet. Korkeus auttaa järviruokoa kilpailemaan auringonvalosta, kun taas runsas harova juurakko vie tilaa muita kasveilta tukahduttaen niiden kasvun. Ruovikon kokonaisbiomassasta jopa noin 75-80 % on juurakkoa (Huhta 2008). Järviruoko hyödyntää juurakkoaan leviämiseen, ja juurakon avulla ruovikko voi levitä useita metrejä vuodessa (Huhta 2008). Järviruoko voi kasvattaa korsiaan, jopa kymmenen metrin päähän juurakostaan. Järviruoko juurakon elinkaari on noin 5-7 vuotta (Huhta 2008).

Ruovikoissa elävät lajit etsivät ruovikoista suojaa ja ravintoa. Ruovikot ovat tärkeitä pesintäpaikkoja linnuille. Monet lintulajit pesivät ainoastaan ruovikoissa, ja niillä alueilla, joilta ruovikot on niitetty pois, ovat lintulajit siirtyneet joko toisiin ruovikoihin tai läheisille niityille (Ikonen & Hagelberg 2007b). Toisaalta ruovikoissa elävät lajit ovat runsastuneet, mikä on paikoitellen hyvä asia, sillä osa ruovikoissa elävistä lajeista, kuten mustatiira (*Chlidonias niger*) tai liejukana (*Gallinula chloropus*) ovat erittäin uhanalaisia (Ikonen & Hagelberg 2007b).

Lintujen lisäksi ruovikoissa elää monia muitakin lajeja kuten sammakoita ja saukkoja. Muun muassa Suomessa rauhoitettu viitasammakko (*Rana arvalis*) on yleinen sammakkolaji ruovikoissa (Ikonen & Hagelberg 2007b). Monet kalalajit munivat ruovikoihin. Lajistollisesti tärkeimpiä ovat sellaiset ruovikot, jotka sijaitsevat rantavyöhykkeillä. Harvemmat ruovikot, jotka sijaitsevat usein avovedessä eivät ole ruovikkolajeille niin tärkeitä (Ikonen & Hagelberg 2007b). Osa ruovikkolajeista asuu mosaiikkimaisten ruovikoiden reuna-alueilla.

### 2.1.3 Ruovikon ravinnekierto

Järviruoko on ravinnekierto sellainen, että sitä voidaan hyödyntää rakennetuissa kosteikossa, joiden avulla pyritään suodattamaan ravinteita jätevedestä. Järviruoko kerää itseensä ravinteita, raskasmetalleja sekä muita vesistölle haitallisia aineita (Milke ym. 2020).

Kosteikoiden biologisten prosessien avulla saadaan poistettua ravinteita vesistä, sillä ravinteet jäävät kosteikkoihin. Jäteveden puhdistuksen lisäksi keinotekoisia kosteikoita on hyödynnetty valuma-alueiden vesien puhdistukseen (Milke ym. 2020).

Järviruoko on poikkeuksellisen korkea ympäristöpaineiden sietokyky, mikä auttaa ruokoa valtaamaan alueita, joissa muut lajit eivät sopeutuisi niin nopeasti. Järviruoko kasvaa vaihtelevissa maaperissä. Kuitenkin järviruoko suosii maaperiä, joissa on lähes 97 prosenttia ravinteikasta orgaanista maaperää (Ikonen & Hagelberg 2007a). Maaperän pH:lla ei ole vaikutusta järviruovikon kasvupaikkaan, sillä järviruoko kasvaa usein alueilla, joiden maaperä on typpirikas.

Järviruoko vähentää typpeä ja sulfideja maaperästä paineistetun hengityksen avulla (Huhta 2008). Järviruoko parantaa usein happiolosuhteita vähähappisissa tai hapettomissa maaperissä. Ruovikoiden juuristot hapettavat pohjasedimenttiä. (Huhta 2008). Optimaalinen veden suolapitoisuus järviruokoille on 0-15 ppt (Huhta 2008).

Järviruoko on herkkä alhaisille happipitoisuuksille. Hapettomissa olosuhteissa ruoko kuluttaa enemmän hiilihydraatteja, jolloin ruoko on pakko siirtyä hapettomaan aineenvaihduntaan. Tässä vaiheessa ruoko pystyy kuitenkin korvaamaan hapen puutteen yhteyttämällä. Ruoko selviytyy hapettomissa tai vähähappisissa sedimenteissä kasvisolukon avulla, joka mahdollistaa kaasujen kuljettamisen juurakon ja korren välillä. Näillä keinoilla järviruoko pystyy esimerkiksi tulvan jälkeen hapettamaan juurakkonsa omatoimisesti. Vaikka ruoko kykenee selviytymään ja kasvamaan pelkistetyissä happiolosuhteissa niin se on silloin kuitenkin paljon herkempi ympäristön riskitekijöille (Huhta 2008).

Kun ruokomassa hajoaa, siitä vapautuu ravinteita, jotka kiihdyttävät etenkin rehevöityneissä vesissä mikrobien toimintaa. Hajotessaan ruokomassa aiheuttaa hapen vajautta pohjasedimentissä, jonka seurauksena pohjasedimentti vapauttaa ilmaan metaania ja rikkivetyä. Metaani on hiilidioksidia voimakkaampi kasvihuoneilmiön aiheuttaja.

#### 2.1.4 Ruovikoituminen

Rantojen ruovikoituminen on lisääntynyt voimakkaasti Suomen rannikkoalueilla 1990-luvulla (Alijoki 2013). Tähän syynä ovat ensisijaisesti maatalouden ja teollisuuden ravinnekuormitus, maankäytön muutokset sekä järviruo'on hyödyntämisen väheneminen. Järviruo'olla on pitkä käyttöhistoria. Järviruovikon tärkein hyödyntämiskeino Suomessa on ollut karjan laiduntaminen ruovikoissa, sekä rehukäyttö (Alijoki 2013). Ruokoa on käytetty myös katto- ja eristemateriaalina. Ravinteet valuvat vesistöihin sateiden mukana, mikä edesauttaa ruovikoiden kasvun lisäksi vesistöjen umpeutumista.

Ravinteiden lisäksi ruovikoitumista on viime vuosikymmeninä lisännyt ilmastonmuutos ja siitä seurannut lämpötilojen kasvu sekä rantalaiduntamisen ja niiton loppuminen (Ikonen & Hagelberg 2008). Myös rantarakentaminen on vaikuttanut siihen, että alkuperäinen kasvillisuus on poistunut rannoilta, mikä on antanut tilaa järviruo'on voimakkaalle leviämislle. Ilmastonmuutos ja siitä aiheutuva lämpötilojen nousu aiheuttaa jääpeitteen vähenemistä. Jääpeitteen väheneminen taas aiheuttaa sen, että jää ei riko tai vahingoita järviruokojen korsia ja juurakoita, mikä edistää ruovikoiden kasvua seuraavalla kasvukaudella.

Ruovikoiden leviämistä estää muun muassa syvä vesi sekä voimakkaat virtausolosuhteet. Mitä syvemmillä vedessä järviruoko kasvaa sitä vaikeampaa on hapen kuljetus juuristoon (Huhta 2008). Muita häiritseviä tekijöitä on muu kasvillisuus, aallot ja häiriöt ympäristössä. Ruovikoiden taantumista edistää voimakkaasti juurakoiden rikkoontuminen. Myös rehevöityminen aiheuttaa ruovikoiden taantumista etenkin syvissä vesissä. Toisaalta ruovikoita voidaan pitää myös rehevöitymisen indikaattorilajina.

Ruovikoitumisella on negatiivisia ja positiivisia vaikutuksia. Ruovikoituminen aiheuttaa avointen vesistöjen umpeutumista ja hävittää alueelta toisia kasvilajeja, samalla avoveden määrä vähenee eritoten pienemmissä vesistöissä. Ruovikon umpeenkasvu vähentää erityisesti ruovikoissa elävien lintulajien määrää (Ikonen & Hagelberg 2007b). Mätänevä ruoko tuottaa paljon metaanipäästöjä ja kuluttaa happea rantavesissä. Metaanipäästöistä aiheutuu myös voimakkaita hajuhaittoja, joka veneväylien umpeutumisen ohella vähentää rannoilla sijaitsevien rantakiinteistöjen, kuten mökkien arvoa, mikä vähentää virkistyskäyttöä ruovikkoisilla alueilla.

Ruovikoiden positiivisia puolia on, että ruovikot sitovat juuriinsa ravinteita ja pidättävät kiintoaineista. Ruovikot torjuvat tehokkaasti aaltojen aiheuttamaa rannikoiden eroosiota sekä heikentävät planktonlevien kasvua vesistöissä. Ruovikoilla on myös virkistyskäyttöarvoja, joita voidaan hyödyntää elämys- tai luontomatkailussa (Juvonen & Kurikka 2016).

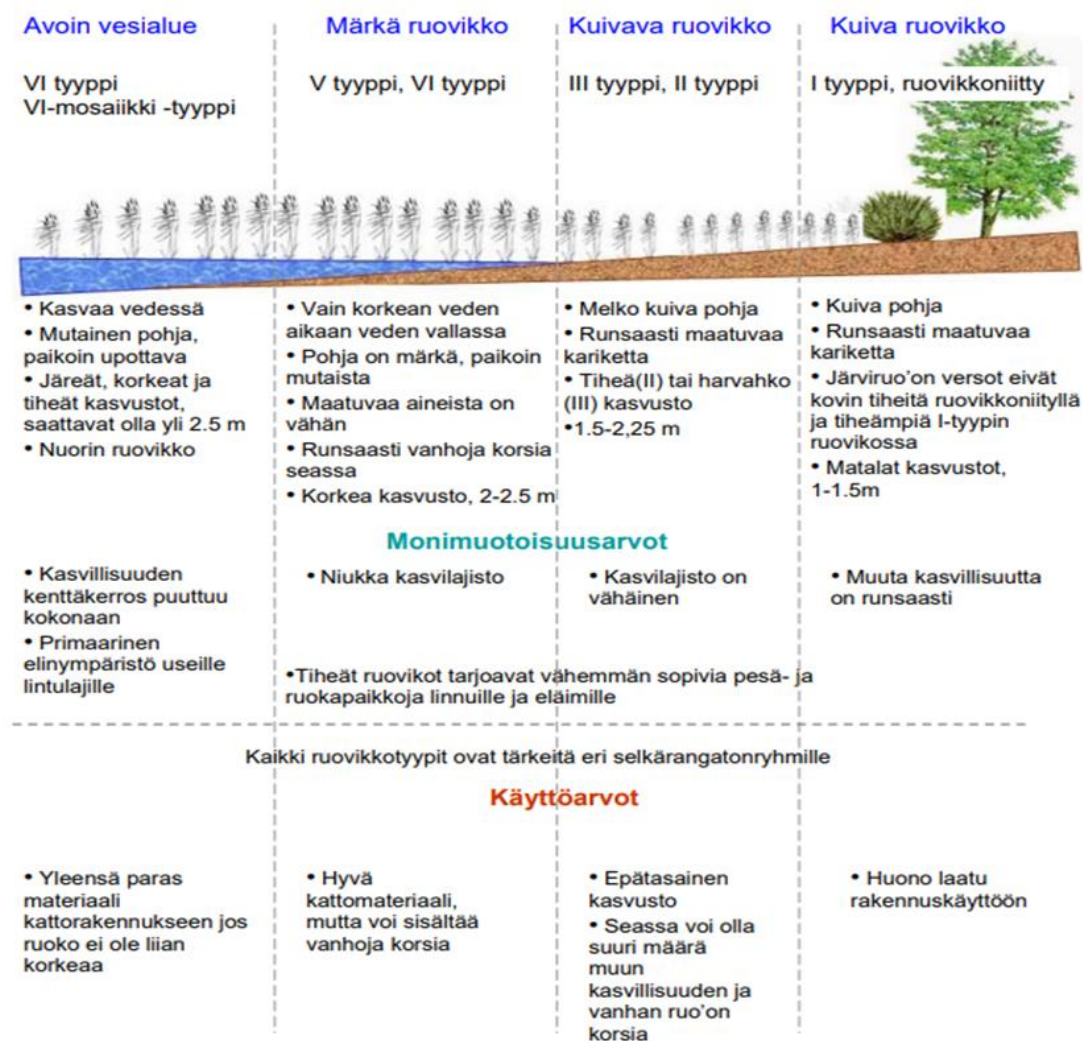
### 2.1.5 Ruovikkoluokittelu

Vaikka ruovikot muodostuvat pääasiallisesti yhdestä lajista voidaan niistä erottaa eri ruovikkotyyppejä. Ruovikot luokitellaan tyypillisesti kuuteen eri luokkaan (kuva 1). Ruovikkoluokat vaihtelevat rannan suuntaisina vyöhykkeinä, joiden erilaisuus johtuu ruovikon suknessio- eli kasvuvaiheista (Ikonen & Hagelberg 2007b). Eri ruovikkoluokat vaihtelevat korkeuden, tiheyden sekä kasvupaikan syvyyden mukaan. Järviruo'on suknession nuorin ruovikkoluokka kasvaa vedessä, kun taas vanhimmat ruovikot kasvavat kuivalla maalla, jossa kasvustot ovat huomattavasti matalampia kuin vedessä sijaitsevat ruovikot (kuva 1).

Järviruo'on kasvu alkaa vesirajasta tai matalasta vedestä, josta järviruo'ko levittäytyy juurakkonsa avulla syvempään veteen, jossa nuorimmat ruovikot kasvavat. (Huhta 2008). Vesirajassa kasvavat järviruo'ot saattavat olla myös edellisvuotisia. Vesirajaan kasaantuu ajan myötä enemmän maatuvaa ruokoainesta ja lopulta osa järviruo'osta kasvaa kuivalla maalla. Tässä maatuvassa ruokoaineessa on usein mukana siementaimia, joista uuden ruovikon kasvu alkaa (Huhta 2008). Nämä siementaimet vaativat kuitenkin paljon auringonvaloa, joten järviruo'on kasvullinen leviäminen juurakon avulla on tyypillisempää (Huhta 2008).

Kuivalla maalla kasvavia ruovikoita kutsutaan ruovikkoniityiksi ja niiden kasvusto on matalampaa kuin vedessä (kuva 1) (Ikonen & Hagelberg 2007b). Kuivalla maalla järviruo'koa saatetaan havaita esimerkiksi peltojen reunoilla tai ojissa, missä järviruo'ko kasvaa kasvupaikkareliktinä, mikä tarkoittaa, että paikka on joskus ollut vesistöjen lähellä, ja maankohoamisen myötä siirtynyt kauemmas vesistöistä (Huhta 2008). Tärkein ruovikkoluokka biodiversiteetin kannalta on vedessä kasvavien mosaiikkimaisten ruovikkolaikkujen reuna-alueet. Ruovikkorakenteen monipuolisuus lisää monipuolista linnustoa ruovikoissa. Myös erilaiset lammikot ruovikoissa ovat tärkeitä. Ne edistävät Euroopan unionin luontodirektiivin lajien kuten viitasammakon elinvoimaisuutta (Ikonen & Hagelberg 2008).

Ruovikon hyödyntämiseen soveltuvimmat luokat ovat vedessä kasvavat ruovikkoluokat (kuva 1). Tämä perustuu siihen, että niiden niittäminen on helpompaa sekä ruoko on korkeampaa ja tasalaatuisempaa kuin maalla kasvava ruoko, jonka seassa usein kasvaa myös muita lajeja (Ikonen & Hagelberg 2007b). Järviruovikon biomassassa on myös tiheämpää avoimella vesialueella, muutaman metrin päässä vesirajasta.



Kuva 1. Oeschin ruovikkoluokittelu vuodelta 1994 (Ikonen & Hagelberg 2007b) mukailten.

## 2.2 Kasvillisuuden kaukokartoitus

### 2.2.1 Kasvillisuuden kaukokartoituksen tavoitteet

Kaukokartoitus on kartoitettavasta kohteesta etänä tapahtuvaa mittausta ilman fyysistä kontaktia itse kohteeseen (Fotso Kamga ym. 2021). Kaukokartoituksessa hyödynnetään esimerkiksi satelliitteihin, lentokoneeseen tai droneen kiinnitetyjä sensoreita, joiden avulla saadaan erilaista tietoa kartoitettavasta kohteesta (Jones & Vaughan 2010: 3). Kaukokartoitus mahdollistaa laajojenkin alueiden kartoituksen. Kaukokartoitusta voidaan hyödyntää esimerkiksi sellaisia alueilla, jotka ovat vaikeakulkuisia. Satelliittikaukokartoitus mahdollistaa laajojen alueiden säännöllisen kartoituksen (Fotso Kamga ym. 2021). Kaukokartoituksen avulla voidaan myös seurata kasvillisuuden muutoksia ajassa sekä analysoida lajirikkautta.

Aktiiviset kaukokartoitussensorit sekä lähettävät, että vastaanottavat sähkömagneettista säteilyä. Aktiivinen kaukokartoitussensori on esimerkiksi laserkeilain, joka lähettää mittaussäteen, jonka paluusignaalin vastaanotin tallentaa (Jones & Vaughan 2010: 113). Passiiviset kaukokartoitussensorit ainoastaan vastaanottavat kohteesta heijastuvaa auringosta peräisin olevaa heijastusta (Jones & Vaughan 2010: 108). Passiivisia kaukokartoitussensoreita ovat muun muassa Landsat- ja Sentinel-satelliittien sensorit.

Kasvillisuuden kaukokartoitukseen voidaan käyttää hyperspektri tai multispektridataa. Hyperspektridata sisältää yksityiskohtaisempaa tietoa ja siinä on enemmän aallonpituuskanavia, kuin multispektridatassa (Jones & Vaughan 2010: 163). Hyperspektridatan käsittely vie enemmän aikaa kuin multispektridatan.

Kasvillisuuden kaukokartoituksen tavoitteena on saada tietoa kartoitettavasta kohteesta, kuten järviruo'osta ja sen spektraalisista ominaisuuksista. Kasvillisuuden kaukokartoituksen tarpeina voi olla esimerkiksi kasvitautien levinneisyyden selvittäminen laajoilla peltoalueilla tai esimerkiksi järviruoovikon vedenpäällisen biomassan määrä. Kaukokartoitusta hyödynnetään myös metsäinventoinneissa sekä latvustojen korkeuden määrittämisessä.

Kasvillisuuden kaukokartoituksessa kiinnostuksen kohteena on usein kasvien lehdet. Kasvien lehtien heijastavuus riippuu lehtien fysiologisista ominaisuuksista, kuten muodosta tai kemiallisesta koostumuksesta. Myös säteilyn tulokulmalla on merkitystä siihen, kuinka paljon lehdestä heijastuu säteilyä pois päin (Jones & Vaughan 2010: 37). Kasvillisuuden heijastusspektrin korkeimmat arvot havaitaan lähi-infrapunasäteilyn aallonpituuksilla, tästä syystä lähi-infrapunan kanavia käytetään paljon kasvillisuuden kaukokartoituksessa.

Kasvillisuuden heijastusspektriin vaikuttaa kasvin kemiallisen koostumuksen ja fyysisen rakenteen lisäksi, myös kasvin vesipitoisuus. Veteen absorboituu merkittävä osuus kasviin tulevasta auringon sähkömagneettisesta säteilystä, ja kasvien heijastusspektrissä tapahtuukin notkahdus näillä aallonpituusalueilla noin 1450 ja 1940 nanometrin kohdalla, heijastusarvojen jääden pienemmiksi näillä aallonpituuksilla (Jones & Vaughan 2010: 164).

## 2.2.2 Kosteikoiden kaukokartoitus

Kosteikkojen vesikasvillisuuden kartoitus on tärkeää suojelun, suunnittelun ja hallinnan kannalta. Kartoitusta voidaan hyödyntää tutkimukseen, suojeluun, hallintaan tai kaupalliseen tarkoitukseen. Kosteikoiden kartoitus on perustunut aikaisemmin pääasiassa maastomittauksiin, mutta maastomittaukset vievät aikaa, jos kartoitetaan suuria alueita. Jatkossa tulisikin kehitellä menetelmiä, joiden avulla voitaisiin mahdollisimman pienillä kustannuksilla kartoittaa suuria kosteikkoalueita. Kaukokartoitus vastaa vesikasvillisuuden kartoituksen tarpeisiin. Kaukokartoitusmenetelmät kehittyvät jatkuvasti, kun satelliittikuvien tarkkuus ja laatu paranee. Kaukokartoitusmenetelmät tarjoavat kestävä ja tarkan menetelmän kosteikoiden kartoitukseen (Adam ym. 2010).

Kosteikoiden kaukokartoitus eroaa muun kasvillisuuden kartoituksesta nimenomaan kartoitettavan kohteen takia. Vesikasvit kasvavat veden ja maan välissä, joten niiden kaukokartoitus on erilaisempaa kuin maalla kasvavien kasvien (Tuominen & Lipping 2016). Kosteikoiden kasvien heijastusarvojen samanlaisuus aiheuttaa myös hankaluuksia kartoitukseen. Sähkömagneettisen spektrin aallonpituuksista vesikasvillisuuden kartoituksen sopivat parhaiten aallonpituudet, jotka ovat lähellä punaista ja infrapunakanavaa heijastukseltaan (Adam ym. 2010).

Kosteikoiden kartoituksen haasteina on multispektraalisen satelliittikuvan suuri resoluutio, koska vesikasvillisuus muodostaa usein pieniä teräväreunaisia alueita ja isoimmilla vuorovesikosteikoilla kasvaa useampia lajeja (Doughty ym. 2021). Monessa tutkimuksessa on havaittu, että Sentinel 2 -satelliitin 10 metrin resoluutio soveltuu hyvin vesikasvillisuuden kaukokartoitukseen (muun muassa Stratoulis ym. 2015; Thamaga ym. 2021).

MODIS-sensorin kuvia käyttivät kosteikoiden biomassan arviointiin Lumbierres ja muut (2017), jotka selvittivät espanjalaisen kosteikon maanpäällisen biomassan määrän muutoksia käyttämällä maastomittauksia ja MODIS-sensorin kuvista laskettua NDVI-indeksiä. Parhaiten heidän tutkimuksessaan toimi NDVI-indeksi, johon oli sisällytetty viidentoista vuoden



aikasarja NDVI-arvoista. Muutoksia arvioitiin lineaaristen regressiomallien avulla, jotka arvioivat biomassan 65 prosenttisesti oikein (Lumbierres 2017). He toteavat tutkimuksessaan, että kaukokartoitusmenetelmien ja maastomittausten yhteiskäyttö tulee olemaan tulevaisuudessa tärkeä työkalu kosteikoiden tilan tutkimuksessa ja monitoroinnissa.

Kosteikoiden biomassaa arvioivat myös Doughty ja muut (2021), jotka kartoittivat useamman kosteikon Kaliforniassa, Yhdysvalloissa. He käyttivät biomassan arvioinnissa tarkkaresoluutioisia ilmakuvia ja Landsat-satelliittikuvia. Heidän tutkimuksissaan biomassaarviointi onnistui paremmin tarkkaresoluutioisilla kuvilla, kuin Landsat-kuvilla. Parhaimman tuloksen he kuitenkin saavuttivat näiden yhdistelmällä, jossa he käyttivät mallinnuksessa tarkkaresoluutiokuvista tehtyjä biomassakarttoja, mutta Landsat-kuvista laskettuja NDVI-arvoja (Doughty ym. 2021).

Kaupallisten satelliittikuvien kalliit hinnat estävät niiden käytön monessa tutkimuksessa. Kosteikoiden tutkimuksessa onkin siirrytty käyttämään satelliittikuvien lisänä droneja tai miehittämättömiä pienlentokoneita (*UAVs, unmanned aerial vehicles*) (Abeysinghe ym. 2019). Näiden etuna on helppo käyttö, sekä se, että sään salliessa kuvia voi ottaa, koska vaan. Hankalaa on kuitenkin ajankäyttö. Suurien alueiden kuvaaminen vie paljon aikaa ja resursseja.

### 2.2.3 Järviruo'on kaukokartoitus

Järviruovikon kaukokartoitukseen on käytetty monia eri menetelmiä ja sensoreita erilaisin lopputuloksin. Pääasiassa järviruovikon kaukokartoituksessa on keskitytty aikasarja-analyyseihin ja järviruo'on leviämisen muutoksen kartoitukseen. Aikasarja-analyysia hyödynsi tutkimuksessaan muun muassa Davranche ja muut (2010), jotka kartoittivat resoluutioltaan 10 metriä olevista SPOT5 satelliittikuvista järviruovikon pinta-alaa Camarguen alueella Ranskassa. Heidän käyttämällään menetelmänä järviruovikot luokittuivat noin 98 prosenttisesti oikein. Menetelmänä tutkimuksessa käytettiin päätöksentekopuita (Davranche ym. 2010). Järviruovikon biomassan kartoittaminen on jäänyt vähäisemmälle tarkastelulle aikaisemmissa tutkimuksissa.

Järviruoko erottuu todella hyvin muusta kasvillisuudesta, kun ruovikkoa tarkastellaan väärävärivärikuvista. Väärävärivärikuvissa ruovikko erottuu muusta kasvillisuudesta kirkkaan vihreänä, kun taas muu elinvoimainen kasvillisuus, kuten metsät erottuvat väärävärivärikuvassa tummanpunaisena. Värierot väärävärivärikuvassa eri ruovikoiden välillä johtuvat järviruo'on

kasvupaikan kosteudesta, kasvin vesipitoisuudesta sekä ruovikon tiheydestä (Ikonen & Hagelberg 2007b). Järviruovikon heijastusarvot erottuvat hyvin loppukesästä muusta kasvillisuudesta, sillä järviruo'on heijastusarvot vihreällä ja punaisella kanavalla ovat hyvin samanlaisia, ja lähi-infrapunalla heijastusarvo on matalampi, kuin muilla kasveilla, johtuen sen värityksestä (Abeysinghe ym. 2019).

Etelä-Suomessa ja Virossa järviruokojen hehtaarimääriä kartoittanut Timo Pitkänen käytti kartoitustyössään resoluutioltaan  $30 \times 30$  metriä Landsat-kuvia ja kartoitti järviruokoja satelliittikuvista Maximum Likelihood -menetelmällä (Pitkänen 2006). Maximum Likelihood -menetelmällä toteutettu kartoitus luokitteli järviruo'ot 70 prosenttisesti oikein. Pitkänen (2006) toteaa, että loppukesä soveltuu parhaiten järviruokojen kartoitukseen. Hän perustelee Landsat-satelliitin valintaa sillä, että Landsatilla on suuri spektraalinen kattavuus ja kartoittaminen Landsat-kuvien avulla on yleispiirteisellä tasolla edullista ja nopeaa.

Stratoulia ja muut (2015) kartoittivat järviruokoesiintymiä Unkarissa niin Sentinel 2 kuin Landsat 8 -satelliittikuvilla. He toteavat artikkelissaan, että Landsatin 30 metrin resoluutio on liian karkea ja epätarkka pienten alueiden kartoitukseen, mutta heidän mukaansa Sentinel 2 -satelliitilla on paljon potentiaalia kosteikoiden tarkempaan kartoitukseen. Satelliittikuvien lisäksi he hyödynsivät tutkimuksessaan ilmakuvia. He käyttivät luokitteluun tukivektorikonetta (*support vector machine*), joka luokitteli kuvat hyvin (Stratoulia ym. 2015).

Tarkempia satelliittikuvia käyttivät muun muassa Onojeghuo ja Blackburn, jotka vuonna 2016 julkaistussa artikkelissa kartoittivat järviruokoa Quickbird-satelliittikuvista. Onojeghuon ja Blackburnin (2016) käyttämällä Maximum Likelihood -menetelmällä järviruo'on luokittelutarkkuus oli noin 78 %. He käyttivät tutkimuksessaan myös muita menetelmiä, mutta Maximum Likelihood -menetelmä saavutti parhaimman tuloksen. Quickbird-kuvia käyttivät tutkimuksessaan myös Gilmore ja muut (2008), jotka kartoittivat Connecticutin vuorovesikosteikon, jossa kasvaa järviruo'on lisäksi muitakin kosteikkokasveja. Quickbird-kuvien lisäksi tutkimuksessa hyödynnettiin lentokoneesta kuvattua laserkeilausaineistoa. Luokittelumenetelmänä Gilmore ja muut (2008) käyttivät objekteihin perustuvaa kuva-analyysimenetelmää, joka kartoitti järviruo'on 97 prosenttisesti oikein.

Rupasinghe ja Chow-Fraser käyttivät vuonna 2021 WorldView-satelliitin kuvia, joiden spatiaalinen resoluutio on 30-40 cm riippuen satelliitista. Menetelminä he käyttivät Maximum Likelihoodia ja tukivektorikonetta, joista tukivektorikone luokitteli paremmin Sentinel 2 -kuvat, kun taas Maximum Likelihood paremmin WorldView-kuvat. Rupasinghe ja Chow-Fraser (2021) toteavat artikkelissaan, että WorldView-satelliitti soveltuu Sentinel 2 -satelliittia paremmin järviruokojen kartoitukseen ja luokittelutuloksetkin olivat parempia. He suosittelevat artikkelissaan käyttämään maskia peittämään tarpeettomat maanpeiteluokat, jotta ne eivät häiritse analyysiä. He toteavat myös, että Sentinel 2 -satelliittikuvan luokittelutarkkuus parani, mitä korkeampi järviruokokasvusto oli.

Tuominen ja Lipping (2016) hyödynsivät omassa tutkimuksessa hyperspektri ja LiDAR -dataa. Käyttämällä tutkimuksissaan LiDAR-dataa eli laserkeilausaineistoa, erottuivat järviruokot paremmin ympäristöstään, sillä järviruokokasvusto on usein korkeampaa kuin sen seassa kasvava kasvillisuus. Samaan lopputulokseen LiDAR:in käytön suhteen pääsivät Onojeghuo ja Blackburn (2011), joiden mukaan LiDAR:in perusteella tehty latvusmalli on tärkeä elementti kasvillisuuden kaukokartoituksessa parantaen luokittelun tuloksia.

Dronekuvia, sekä miehittämättömien pienlentokoneiden kuvia on käytetty paljon myös järviruokojen kartoituksessa. Muun muassa Abeysinghe ja muut (2019) käyttivät tutkimuksessaan pienlentokonetta, jossa oli kamera, joka kuvasi tutkimusalueen viidellä eri aaltopituuskanavalla. Aineisto luokiteltiin kolmella eri luokittelumenetelmällä, joista heidän tutkimuksessaan paras oli pikseleiden arvoihin perustuva neuroverkko, joka luokitteli järviruovikon 94 prosenttisesti oikein (Abeysinghe ym. 2019). Tutkimusalue rajattiin NDVI-arvojen perusteella, jotta saatiin rajattua vesipinnat sekä rakennettu ympäristö pois luokittelusta. Ilmakuvia hyödynsivät järviruokojen kartoittamisessa myös Anderson ja muut (2021), jotka kartoittivat järviruokoesiintymiä kahdella alueella Yhdysvalloissa. He saivat tutkimuksessaan parhaimmat luokittelutulokset yhdistämällä ilmakuvan ja ilmakuvasta lasketun latvusmallin. Heidän luokittelutuloksensa oli noin 90 prosenttia (Anderson ym. 2021).

### 3 Tutkimusalue

Tutkimusalueeksi valittiin Lemlahden saari, joka valittiin siksi, että saaren ruovikoilta oli aikaisemmin vuonna 2020 Turun ammattikorkeakoulun toimesta leikattu näyteleikkuita, joiden tuloksia saatiin hyödyntää tässä tutkimuksessa. Näyteleikkuita leikattiin gradua varten lisää saaren suurimman ruovikon Brattnäsvikenin alueelta syksyllä 2022. Lemlahden saari sijaitsee Paraisten kaupungissa, Saaristomeren alueella.

Saaristomeri sijaitsee Ahvenanmaan ja Suomen mantereen välillä ja se on osa Itämeren merialuetta (kuva 2). Pohjois-Euroopassa sijaitsevalla hauraalla Itämeren merialueella on lyhyt historia. Itämeri muodostui viimeisimmän jääkauden jälkeen noin 10000-15000 vuotta sitten (Myrberg ym. 2009). Itämeren rannikkoalueet ovat saaristoisia. Itämeren pohja kohoaa muutamia millimetrejä vuodessa.

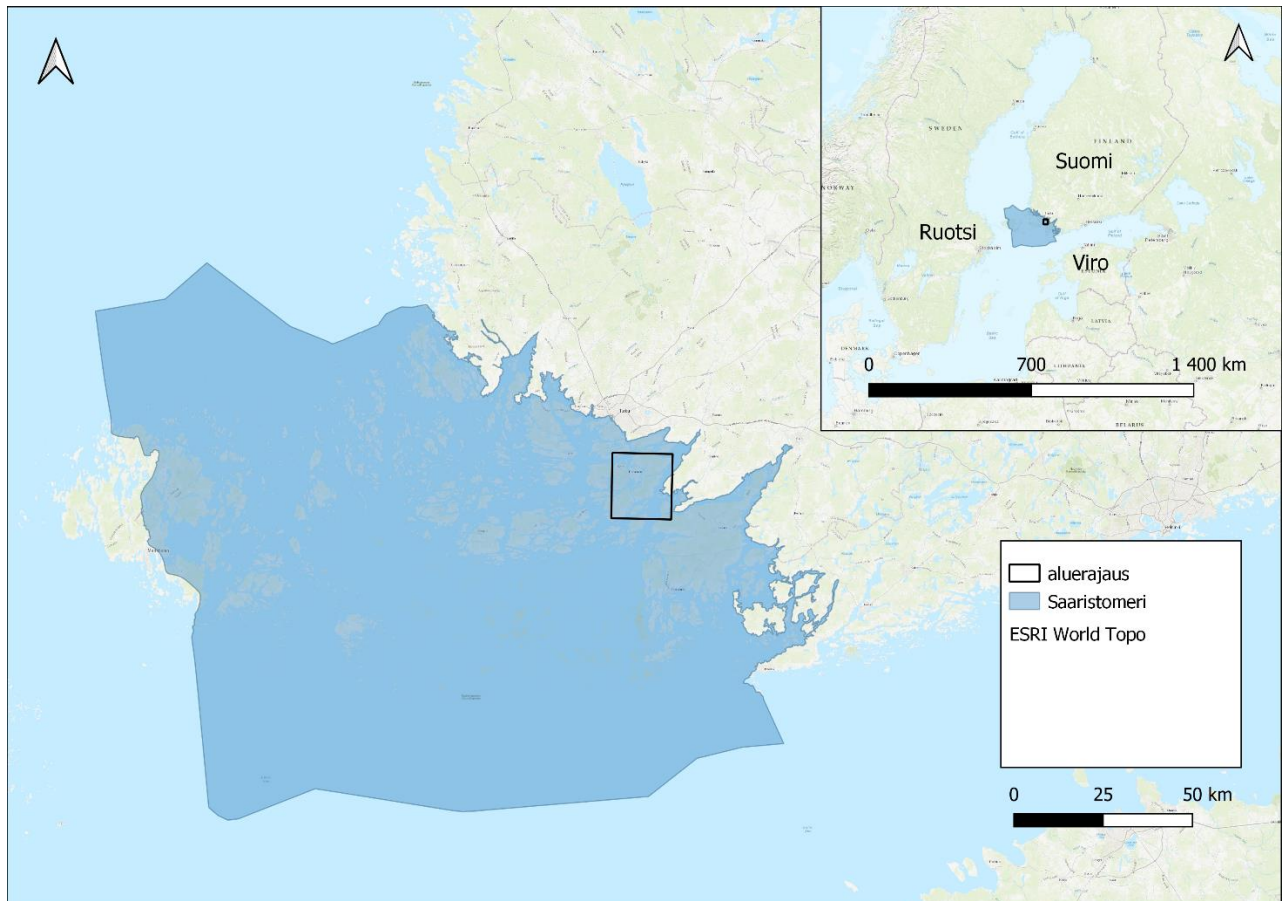
Itämeren mataluus ja suolapitoisuus tekevät siitä herkän merialueen muutoksille (Myrberg ym. 2009). Pienetkin muutokset eliöstössä ja elinolosuhteissa vaikuttavat Itämeren lajien tilaan. Itämeren keskisyvyys on noin 60 metriä ja syvimmillään se on vain 460 metriä (Ojaveer ym. 2010). Saaristomeri on matala vesi-alue, jonka syvyys on alle 40 metriä (Myrberg ym. 2009). Itämeren vesi on murtovettä, jonka suolapitoisuus vaihtelee alueittain 1 ja 30 promillen välillä (Andersen ym. 2017). Saaristomerellä suolapitoisuus on alle 7 promillea (Andersen ym. 2017).

Itämeren lajeista suurin osa elää sopeutumiskykynsä rajoilla. Tämä sopii järviruo'olle, jonka kasvulle on optimaalista matala suolapitoisuus. Järviruo'on ympäristöpaineiden sietokyky ja kyky hapettaa pohjasedimenttiä, mahdollistaa sen lisääntymisen Itämeren vähähappisessa vedessä. Hapettomuus on Itämerellä yleistä etenkin Saaristomeren sisä- ja välisaariston suojaisilla lahdilla (Korpinen ym. 2018). Näillä matalilla ja suojaisilla lahdilla on usein muta-, leiju- tai hiekkapohja, mikä soveltuu hyvin järviruovikon kasvulle (Myrberg ym. 2009).

Itämeren ravinnekuormitus on suurta, sillä Itämereen valuu ravinteita 14 eri valtion alueelta (Ojaveer ym. 2010). Ravinnekuormitus Itämerellä on kasvanut voimakkaasti 1940-luvulta lähtien (Andersen ym. 2017). Valuma-alueen pinta-alaan suhteutettuna suurimmat ravinnekuormitukset havaittiin vuosina 2011-2016 Saaristomeren alueella (Korpinen ym. 2018). Saaristomeri on kooltaan noin 8,893 km<sup>2</sup> (Myrberg ym. 2009). Suurimmat Saaristomeren ravinnekuormituksen lähteet ovat maatalouden ja teollisuuden typpi- ja

fosforipäästöt. Yksi keinoista vähentää Itämeren ravinnekuormitusta on poistaa järviruokoa rannoilta.

Suomen rannikkovedet ovat rehevöityneet runsaasti viimeisten vuosikymmenien aikana. Tilanne on huolestuttava etenkin Saaristomerellä, jossa veden vaihtuminen on hidasta (Korpinen ym. 2018). Veden hidas vaihtuminen lisää rehevöitymistä ja järviruovikon leviämistä.



Kuva 2. Saaristomerren sijainti.

Tarkempaan tutkimukseen Lemlahden saarelta valitut järviruovikot ovat Kassor, Rapusviken ja Brattnäsviken (kuva 3). Kaikki tutkimukseen valitut järviruovikot ovat merenlahdella sijaitsevia, ja niissä on paljon erilaisissa olosuhteissa kasvavaa ruokoa. Brattnäsvikenin ruovikko tyypillinen ruovikko, jossa on tiheitä ruokokasvustoja kuivalla maalla ja vedessä mosaiikkimaisia laikkuja (kuvat 4 ja 5). Kooltaan Brattnäsvikenin tutkimusalue on 60 hehtaaria. Kassorin tutkimusalue on kooltaan 34 hehtaaria ja Rapusviken 24 hehtaaria. Koko tutkimusalueen pinta-ala (ala, jolla Sentinel 2 -satelliittikuvat rajattiin) on 28911 hehtaaria eli 289 neliökilometriä (kuva 3).



Kuva 3. Tutkimusalueiden sijainti Paraisten kaupungin alueella.





Kuva 4. Brattnäsvikenin järviruovikko dronella kuvattuna 31.08.2022. Kuvaussuunta pohjoisesta etelään päin. Kuva: Jerome Tornikoski, Turun ammattikorkeakoulu.





Kuva 5. Brattnäsvikenin järviruovikko länsirannan pelloilta kuvattuna 08.09.2022. Kuva: Roosa Väisänen



## 4 Aineistot ja menetelmät

### 4.1 Aineistot

#### 4.1.1 Satelliittikuva-aineistot

Tutkimuksessa satelliittikuva-aineistona Kassorin ja Rapusvikenin osalta käytettiin ESA:n (European Space Agency) Sentinel 2 -satelliittikuvaa päivältä 02.10.2022. Kyseisen päivän satelliittikuva oli pilvetön. Brattnäsvikenin osalta käytettiin ESA:n Sentinel 2 -satelliitin kuvaa päivältä 30.8.2022. Valitussa kuvassa oli muutama pilvi, mutta ne eivät osuneet tutkimusalueen päälle. Mahdollisimman pilvetön kuva siksi, että pilvet haittaavat satelliittikuva-analyysiä, sillä pilvet heijastavat auringon säteilyn satelliittiin eikä auringon säteily saavuta maanpintaa.

Nämä päivät valittiin siksi, että ne olivat kenttäpäiviä lähimmät päivät, jolloin Sentinel 2 -satelliitti oli ottanut mahdollisimman pilvettömän kuvan ennen näyteleikkuita. Satelliittikuva tuli valita ajalta ennen näyteleikkuita, sillä näyteleikkuit näkyisivät muuten analyysien tuloksissa, ja analyysissä haluttiin selvittää etenkin Brattnäsvikenin ruovikon biomassaa ennen leikkuita, sillä ruovikko leikattiin pian näyteleikkuiden jälkeen. Ruovikko ei kasvukauden ulkopuolella muutu niin nopeasti, että yli viikon ero leikkuiden ja satelliittikuvan välillä vaikuttaisi merkittävästi analyysin tulokseen.

Sentinel 2 -satelliitin temporaalinen resoluutio on viisi päivää ja sen resoluutio vaihtelee kanavittain 10 - 60 metrin välillä (Resolutions s.a). Sentinel 2 -satelliittia on hyödynnetty paljon aikaisemmassa kosteikkotutkimuksessa sen kohtuullisen hyvän resoluution vuoksi (Stratoulas ym. 2015; Rupasinghe & Chow-Fraser 2021). Sentinel 2 -satelliitin kuvat ovat vapaasti kenen tahansa ladattavissa ESA:n rajapinnasta eikä kuvien hyödyntäminen maksa mitään. Kuvien laatimiseksi tulee luoda käyttäjätili. ESA:n rajapinnasta on mahdollista ladata raakakuva tai valmiiksi ilmakehäkorjattu kuva. Tässä tutkimuksessa on käytetty valmiiksi ilmakehäkorjattuja luokan level 2A -satelliittikuvia.

#### 4.1.2 Biomassa-aineistot

Kenttätyöt Kassorin ja Rapusvikenin lahdella tehtiin 28.10.2020 Turun ammattikorkeakoulun väen toimesta. Järviruokoa leikattiin molemmilta lahdilta kolmesta kohdasta (kuva 6).

Näyteleikkuut suoritettiin veneestä käsin. Näyteleikkuupaikat valittiin ennen näytteenottoa ja näytteet leikattiin puutarhasaksilla. Näyteruudut olivat kooltaan 1x2 metriä. Näytteet punnittiin Tammiluodon viinitilan elektronisella omenavaa'alla.

Kenttätyöt Brattnäsvikenin lahdella tehtiin 08.09.2022. Kenttätöiden tarkoituksena oli kerätä mahdollisimman paljon järviruokoa analyysija varten. Kenttätöihin osallistui lisäksi Turun ammattikorkeakoulun projekti-insinööri Jerome Tornikoski. Aikataulun tiukkuuden vuoksi järviruokoa kerättiin kahdeksasta eri kohdasta (kuva 5). Järviruokoa kerättiin kohdista, jotka olivat mahdollisimman erilaisia kasvustoltaan. Ruokonäytteet valittiin paikan päällä, alustava tarkastelu alueesta ennen näytteiden keruuta tehtiin Maanmittauslaitoksen ilmakuvien ja ajantasaisen Turun ammattikorkeakoulun kuvaaman dronekuvan (31.8.) perusteella.



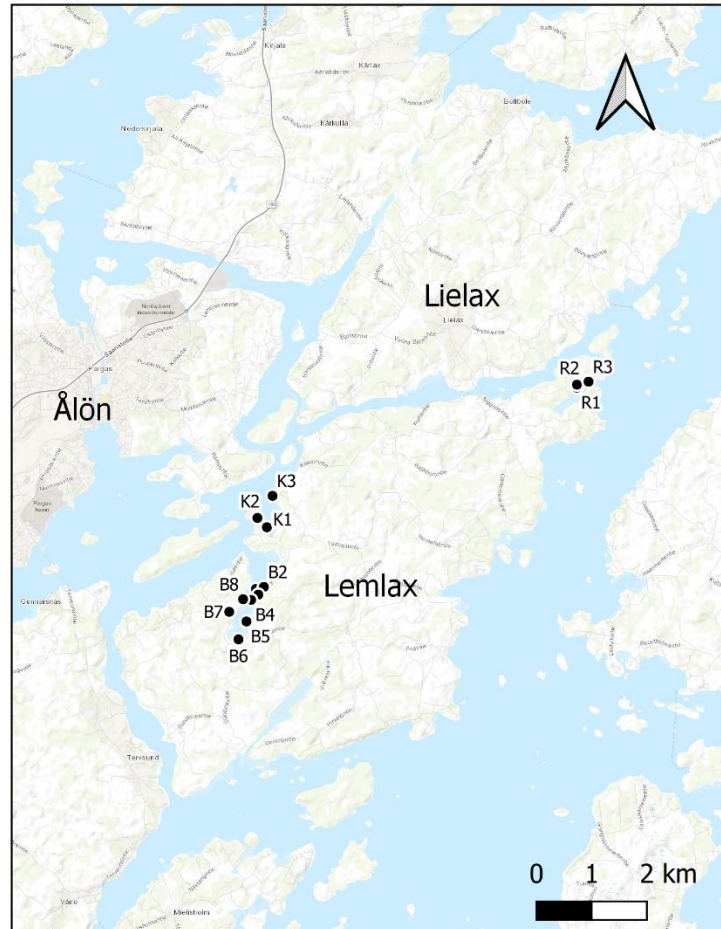
Näytepisteiden koordinaatit kerättiin käsikäyttöisellä Garmin Oregon 700 GPS-laitteella.

Näyteruudut olivat kooltaan 1x1 metriä ja näyteruudut mitattiin kannettavalla neliömitalla. Järviruokot leikattiin puutarhasaksilla ja laitettiin pusseihin odottamaan punnitusta. Leikatut näytteet asetettiin suurikokoisiin jätösäkkeihin niin, että yhden näytepaikan näyte laitettiin yhteen pussiin narulla sidottuna. Lopuksi pussiin merkattiin teippiin kirjoitettuna mikä näyte on kyseessä. Arviolta jokaisen näytteen keräämiseen kului aikaa alle 30 minuuttia.

Järviruokojen punnitus tapahtui Tammiluodon viinitilan antiikkisella omenavaa'alla (kuva 7), jonka tarkkuus ei ollut paras mahdollinen vain on mahdollista, että punnitut arvot heittävät noin 200 grammaa. Tätä heittoa ei ole huomioitu analyysissä, sillä vaa'an luotettavuutta ei pystytty testaamaan ja arvio heitosta perustuu vaa'an omistajan mielipiteeseen. Heitto tulee kuitenkin ottaa huomioon, tulosten tarkastelussa.

Leikattu järviruoko oli märkää ja sen kosteusprosentti kaikilla tutkimusalueilla oli noin 40-55 prosenttia (Tornikoski & Simi-Virahsawmy 2020). Ruo'on kosteusprosentit selvitettiin kuivattamalla ne kuivausuunissa. Sen jälkeen ruokojen massat laskettiin uudestaan kuivabiomassojen määrittämiseksi. Tämän tutkimuksen analyysissä on käytetty näyteleikkuiden märkäbiomassa-arvoja.

- Näyteleikkuut
- Google Satellite
- ESRI World Topo



Kuva 6. Näyteleikkuiden sijainnit tutkimusalueilla, B=Brattnäsviken, K=Kassor ja R=Rapusviken.





Kuva 7. Tammiluodon viinitilan omenavaaka 08.09.2022. Kuva: Jerome Tornikoski, Turun ammattikorkeakoulu.

## 4.2 Menetelmät

### 4.2.1 Satelliittikuvamenetelmät

Ennen analyysijä Sentinel 2 -satelliittikuvat rajattiin pienemmäksi SNAP-ohjelmistolla. Työprosessi on kuvattu vuokaaviona kuvassa 8. SNAP on ESA:n ilmainen ohjelmisto, joka on tarkoitettu satelliittikuva-analyysiin ja ilmakehäkorjauksiin, sillä voi myös luokitella satelliittikuvia eri algoritmeilla (SNAP s.a ).

Huomioitavaa on, että satelliittikuvien esikäsittely ei lisää kuvasta saatavan tiedon määrää, mutta voi muuttaa satelliittikuvan arvoja tai kokoa niin, että kuvan prosessointi ja analysointi ei olisi niin raskasta, sillä satelliittikuvat ovat erittäin suuria (Fotso Kamga ym. 2021).

Arvojen muuttuminen tarkoittaa esimerkiksi analyysille tarpeettomien kanavien poistamista tai kanavien arvojen yhdenmukaistamista samaan pikselikokoon. Kuvat rajattiin tutkimusalueella, jonka rajat on esitetty kuvassa 3.

Aluerajauksen jälkeen kuville tehtiin spektraalinen rajaus. Satelliittikuvien kanavien resoluutiot yhdenmukaistettiin 10 x 10 metrin resoluutioon ja kuvista rajattiin tarpeettomat kanavat pois. Pois rajattuja kanavia käytetään pääasiassa pilvimaskien tekemiseen ja ilmakehäkorjauksiin, joten niiden kanavien heijastusarvot eivät olisi tuoneet lisää tähän tutkimukseen. Myös tarpeettomien kanavien pois rajaaminen pienensi prosessoitavien kuvien kokoa. Kuvista rajattiin pois kanavat 1, 8A, 9 ja 10.

Kaukokartoitussatelliittien dataa voidaan luokitella ohjatuilla ja ohjaamattomilla luokitteluilla, joita käytetään erilaisten asioiden esimerkiksi maankäyttöluokkien erottamiseen tai luokitteluun satelliittikuvista (Fotso Kamga ym. 2021). Näin voidaan tehdä esimerkiksi kasvillisuusteemakarttoja (Jones & Vaughan 2010; 184). Luokitteluja voidaan hyödyntää myös esimerkiksi kasvillisuuden biomassan tai levinneisyyden arvioinnissa.

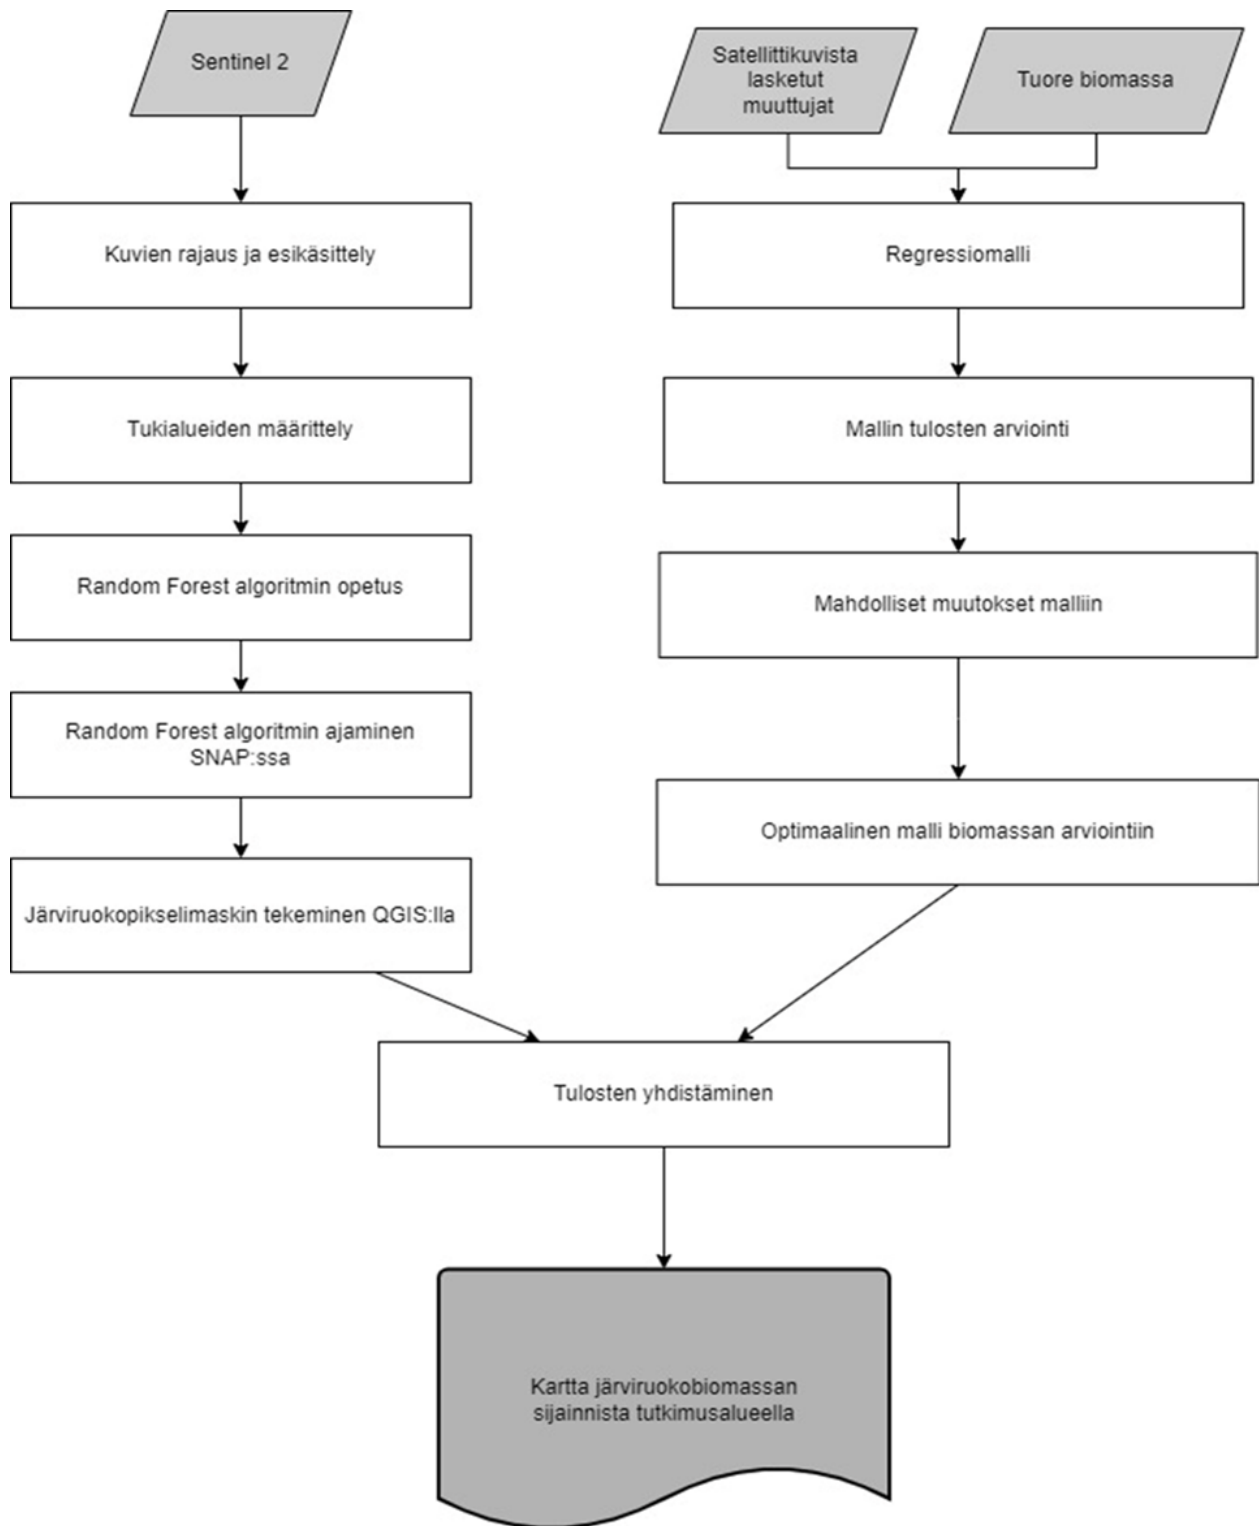
Kasvillisuuden kaukokartoituksessa käytettyjä ohjaamattoman luokittelun menetelmiä ovat muun muassa pääkomponenttianalyysi ja k:n keskiarvon klusterointi (Jones & Vaughan 2010; 147-148; Fotso Kamga ym. 2021). Ennen ohjattua luokittelua Sentinel-kuville tehtiin ohjaamaton k:n keskiarvon klusterointi-luokittelu SNAP-ohjelmistolla.

Ohjaamattomassa luokittelussa määritellään, kuinka moneen luokkaan halutaan, että kuva jaetaan ja tämän jälkeen ohjelmaa jakaa luokat itse heijastusarvojen perusteella (Jones & Vaughan 2010: 187). Ohjaamaton luokittelu ei tarvitse opetusaineistoa (Fotso Kamga ym.

2021). Ohjaamaton luokittelu antaa myös suuntaa siihen, millaisia heijastusarvoja kuvassa on, sekä millä luokilla on samalaiset heijastusarvot. Tällöin kannattaa pohtia, pitäisikö joitain luokkia yhdistää tai sitten erottaa. Tärkeintä ohjatussa luokittelussa on, että luokat erottuvat heijastusarvoiltaan mahdollisimman paljon toisistaan (Jones & Vaughan 2010: 189).

Ohjatussa luokittelussa kuva opetetaan, eli ohjelmistolle annetaan valmiiksi määritelty opetusaineisto, joka voi olla pikseleitä tai objekteja, joiden perusteella ohjelma suorittaa luokittelun (Jones & Vaughan 2010: 188-189; Fotso Kamga ym. 2021). Ohjatulla luokittelulla saadaan usein parempi tulos kuin ohjaamattomalla, mutta ohjaamatonta voidaan käyttää etukäteistarkasteluun, kun pohditaan millaisiin luokkiin kuva kannattaisi jakaa.

Ohjatun luokittelun menetelmiä, joilla on kartoitettu kasvillisuutta, ovat muun muassa neuroverkot, tukivektorikone, Maximum Likelihood, sekä päätöksentekopuut, kuten Random Forest (Jones & Vaughan 2010: 191-192). Ohjatun luokittelun onnistuminen on riippuvainen opetusaineiston laadusta, mitä tarkempi opetusaineisto, sitä tarkemman lopputuloksen luokittelu antaa (Fotso Kamga ym. 2021).



Kuva 8. Kaavio työprosessista.

Ohjatun luokittelun algoritmiksi valittiin aikaisempien tutkimusten perusteella Random Forest -algoritmi, joka perustuu päätöksentekopuihin (*classification trees*) (Jones & Vaughan: 191-192; Zhao ym. 2022). Random Forest -algoritmi ajettiin SNAP-ohjelmistossa 100 puulla. Mitä enemmän puita valitsee algoritmiin, sitä tarkempi on ohjatun luokittelun tulos. Ei-parametriset luokittelut, kuten Random Forest, ovat yhä enemmän käytettyjä vaihtoehtoja perinteisille kaukokartoitustekniikoille kosteikkoluokituksen tarkkuuden parantamiseksi. Päätöksentekopuut ovat hyödyllisiä erottamaan kosteikoiden välisiä ja sisäisiä spektrisiä yhtäläisyyksiä (Davranche ym. 2010).

Ohjattu luokittelu opetettiin kahdeksan maankäyttöluokan avulla (taulukko 1).

Maankäyttöluokat valittiin ohjaamattoman luokittelun tulosten sekä tutkimusalueen yleisimpien maanpeiteluokkien perusteella. Ohjatun luokittelun arviointi tehtiin visuaalisesti tuoreimman Google Satellite -kuvan sekä itsenäisen 158 pistettä sisältävän luokittelun perusteella.

Taulukko 1. Ohjatussa luokittelussa käytetyt luokat

<b>Id</b>	<b>Luokka</b>
1	Vedet
2	Havumetsä
3	Lehtimetsä
4	Ruohomaa, niitty
5	Rakennettu
6	Orastava pelto
7	Avoin maa-alue
8	Järviruoko

Ohjatun luokittelun tuloksia käytettiin järviruokomaskin luomiseen. Maskilla tarkoitetaan aluetta, jota käytetään satelliittikuvan rajaamisen. Usein käytetään, esimerkiksi vesimaskia rajaamaan veden heijastusarvot pois analyysistä (Pitkänen 2006; Abeysinghe ym. 2019).

Tässä tutkimuksessa maskia käytettiin rajaamaan järviruokopikselit ja niiden heijastusarvot satelliittikuvasta. Järviruokopikselimaski tehtiin QGIS: llä. Satelliittikuvan maskaus tehtiin SNAP:ssä.



Heijastusarvojen lisäksi järviruokomaskilla rajattiin SNAP-ohjelmistolla laskettujen kasvillisuusindeksien arvot. Kasvillisuusindeksejä käytetään esimerkiksi kasvitautien havaitsemiseen, kuivuuden monitorointiin tai kasvien vesipitoisuuksien määrittämiseen (Glenn ym. 2008). Kasvillisuusindeksit ovat vertailukelpoisia eri satelliittikuvien välillä, sillä niiden laskentatapa on riippumatta satelliitista.

Suurin osa kasvillisuusindekseistä perustuu laskutoimituksiin eri aallonpituuskaistojen välillä, sekä siihen että kasveilla heijastavuusarvot kasvavat voimakkaasti 700 nanometrin aallonpituusalueella (Jones & Vaughan 2010: 165). Suurin osa kasvillisuusindekseistä hyödyntää punaisen ja lähi-infrapunakanavan laskennallisia vertailuja maanpeitteiden luokittelussa (Glenn ym. 2008).

Tunnetuinta kasvillisuusindeksiä NDVI:tä eli normalisoitua kasvillisuusindeksiä käytetään kasvillisuuden laadun tai määrän mittarina mittauksissa, joissa tarvitaan enemmän, kuin yhden aallonpituuskaistan arvot (Jones & Vaughan 2010: 166). NDVI korreloi merkitsevästi klorofyllin eli lehtivihreän määrän kanssa. NDVI-arvot vaihtelevat usein 1 ja 0 välillä, jossa 1 tarkoittaa 100 prosentista kasvillisuuspeitettä ja 0 avointa maata. 100 prosentin kasvillisuuspeite pikselissä ei kuitenkaan tarkoita, että kasvillisuudella olisi sama kasvillisuusindeksi-arvo, siihen vaikuttavat klorofyllin määrän lisäksi latvuksen rakenne (Glenn ym. 2008).

Kasvillisuusindeksien avulla voidaan myös arvioida biomassan määrää, sekä seurata kasvillisuuden muutoksia aikasarjoina. Valitut kasvillisuusindeksit (NDVI, NDWI, SAVI, DVI, MSAVI) perustuivat aikaisempiin tutkimuksiin järviruovikon levinneisyyden arvioinnista (Davranche ym. 2010; Abeysinghe ym. 2019; Zhao ym. 2022). SAVI -indeksiä käytetään korjaamaan normalisoitua kasvillisuusindeksiä (NDVI) maaperän kirkkauden vaikutuksesta alueilla, joilla kasvipeite on alhainen (Davranche ym. 2010). NDWI:n (*normalized difference water index*) tiedetään olevan vahvasti yhteydessä kasvin vesipitoisuuteen. Siksi se on erittäin hyvä vaihtoehto vesipitoisten kasvien kuten järviruovikon kartoitukseen. DVI-indeksi on yksinkertaisin kasvillisuusindekseistä. Se on herkkä kasvillisuuden määrälle ja erottaa maaperän ja kasvillisuuden toisistaan (Davranche ym. 2010).

#### 4.2.2 Tilastolliset menetelmät

Kasvillisuuden biomassan arvioinnissa on käytetty tilastotieteeseen perustuvia menetelmiä, kuten lineaarisia regressiomalleja ja semivariogrammeja (Doughty ym. 2021; Zhao ym. 2022). Ruovikon biomassan arvioinnissa tärkeimmät käytetyt menetelmät ovat koneoppimiseen perustuvat menetelmät, sekä tilastotieteeseen perustuvat lineaariset regressiomallit. Regressiomallien hyviä puolia on, että ne ovat helposti tulkittavia, mutta taustatekijät saattavat häiritä tuloksia liikaa (Li ym. 2019).

Regressioanalyysi on tilastotieteen menetelmä, jonka avulla selvitetään yhden tai useamman muuttujan suhdetta selitettävään ilmiöön (Tähtinen ym. 2020), kuten tässä tutkimuksessa satelliittikuvan heijastusarvojen suhdetta järviruovikon biomassaan. Regressioanalyysin lopputulos on tilastollinen malli, josta voidaan tulkita, millainen selityssuhde tarkasteltavien muuttujien välillä on ja kuinka suuren osan selitettävän muuttujan vaihtelusta valitut muuttujat selittävät. Regressiomalli sopii myös muuttujan ennustamiseen (Tähtinen ym. 2020).

Tässä tutkimuksessa on käytetty askeltavaa regressioanalyysiä, jossa tilasto-ohjelma arvioi vaihe kerrallaan malliin parhaat selittävät muuttujat. Analyysin tuloksena on malli, jossa on valittuna ainoastaan tilastollisesti merkitsevät muuttujat. Ne muuttujat, jotka eivät tilastollisesti merkitsevästi selitä mallin muuttujien välistä suhdetta jäävät mallin ulkopuolelle. Regressioanalyysin käytöllä pyritään saavuttamaan sellainen tilastollinen malli, jolla on mahdollisimman suuri selitysaste, mutta selitettävien muuttujien määrä on mahdollisimman pieni (Tähtinen ym. 2020).

Käytettäessä askeltavaa regressioanalyysiä tutkimuksessa, on huomioitava, onko olemassa sellaisia tekijöitä, jotka on sisällytettävä malliin, niiden sisällön perusteella vaikkei niiden selityskyky olisikaan tilastollisesti merkitsevä (Tähtinen ym. 2020). Tässä tutkimuksessa tehtiin Spearmanin epäparametriset korrelaatioanalyysit (liitteet 1 ja 2) ennen lineaarista regressioanalyysiä, jossa todettiin, että molemmissa kuvissa oli muuttujia, jotka eivät tilastollisesti merkittävästi korreloineet biomassan kanssa. Ne kuitenkin pidettiin mallissa mukana, koska koin niiden sisällöllisesti soveltuvan malliin. Korrelaatioanalyysien tulkinnassa käytettiin Spearmanin korrelaatiokertomia, sillä muuttujien jakaumat eivät noudattaneet normaalijakaumaa. Tein myös testiksi toisen mallin, jossa muuttujat, jotka eivät tilastollisesti korreloineet biomassansa kanssa, eivät olleet mukana ja sen tulos oli huonompi kuin malli, jossa kaikki muuttujat olivat mukana.

Lineaariseen regressioanalyysiin valittujen kanavien ja kasvillisuusindeksien arvot tuotiin SNAP:sta IBM SPSS Statistics 27 -ohjelmistoon, jossa niitä käytettiin lineaarisen regressioanalyysin tekemiseen. Käytetty askeltava regressiomalli oli enter, jossa jokainen selittävä muuttuja arvioidaan niin kuin se olisi syötetty kaikkien muiden riippumattomien muuttujien syöttämisen jälkeen, ja sen perusteella, mitä se tarjoaa selittävän muuttujan ennusteelle, joka eroaa muiden malliin lisättyjen muuttujien tarjoamista ennusteista (*analyze-regression-method:enter*). Tässä tutkimuksessa järviruovikon biomassan arviointiin käytettiin useamman selvittävän muuttujan lineaarista regressioanalyysiä, jossa heijastusarvot ja kasvillisuusindeksit olivat selittäviä muuttujia ja biomassassa selitettävä muuttuja. Selitettävälle muuttujalle annettiin muutamia arvoja (näyteleikkuut ja useampi vesipikselin arvo), joiden perusteella regressioanalyysi arvioi heijastus- ja kasvillisuusindeksiarvojen perusteella tutkimusalueiden ruovikon biomassan.

## 5 Tulokset

### 5.1 Näyteleikkuut

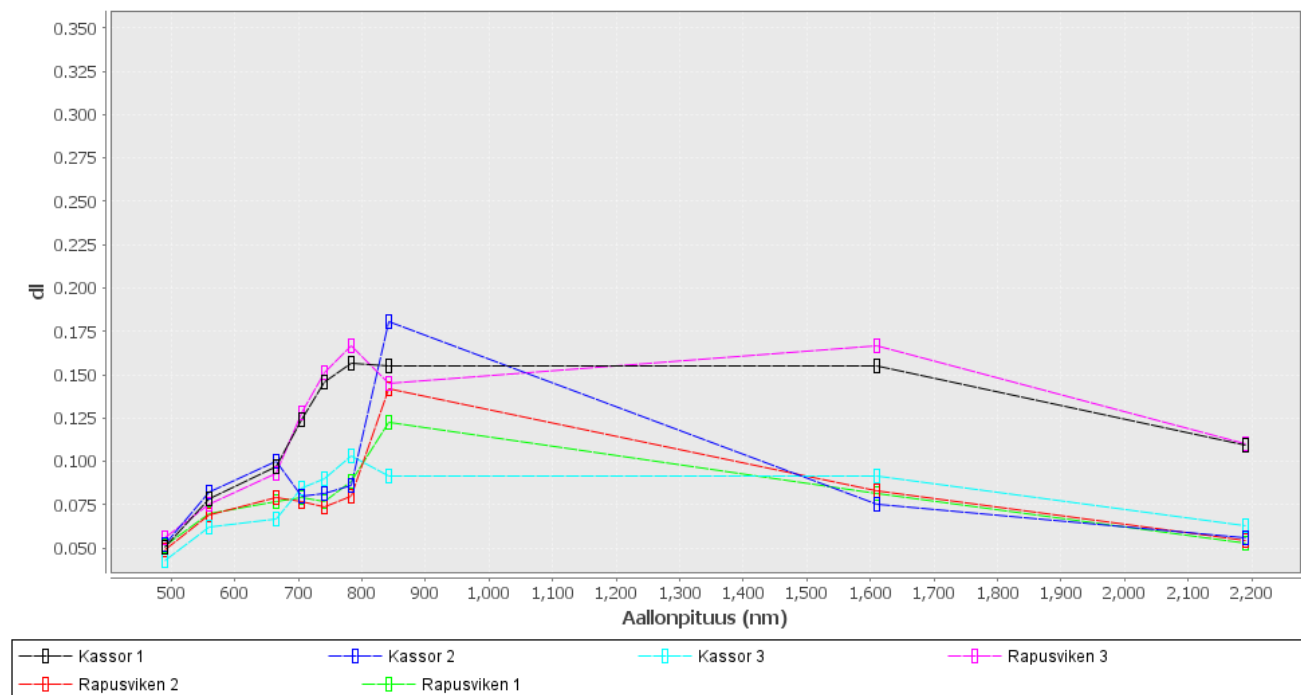
Taulukossa 2 on esitetty näyteleikkuiden biomassat jokaiselta tutkimusalueelta sekä leikkuupäivät. Suurin biomassa näyteleikkuista oli pisteellä Rapusviken 1 ja pienin pisteellä Rapusviken 2. Huomioitavaa on, että Kassorin ja Rapusvikenin pisteiden näyteleikkuuala oli 1 x 2 m ja Brattnäsviken näyteleikkuuala oli 1 x 1 metriä. Keskimääräinen biomassa yhdelle neliömetrille koeleikkuiden perusteella on Kassor 0,83 kg, Rapusviken 1,2 kg ja Brattnäsviken 1,75 kg. Biomassa-arvioiden onnistumisprosentti näyteleikkuiden osalta on 89 prosenttia.

Pienin ero punnitun biomassan ja biomassa-arvion välillä on havaittavissa pisteessä Rapusviken 3. Suurin ero punnitun biomassan ja biomassa-arvion välillä oli pisteessä Rapusviken 1. Keskimääräinen ero punnitun biomassan ja biomassa-arvio välillä oli 0,5 kg.

Taulukko 2. Näyteleikkuiden analyysien tulokset.


Näytepisteet	Biomassa (kg)	Biomassa-arvio (kg)	Leikkuupäivä
Kassor 1	1,91	1,53	28.10.2020
Kassor 2	1,67	1,03	28.10.2020
Kassor 3	1,41	0,86	28.10.2020
Rapusviken 1	4,31	1,18	28.10.2020
Rapusviken 2	0,9	1,38	28.10.2020
Rapusviken 3	1,97	1,91	28.10.2020
Brattnäsviken 1	2	1,65	08.09.2022
Brattnäsviken 2	2,48	2,19	08.09.2022
Brattnäsviken 3	1,38	1,81	08.09.2022
Brattnäsviken 4	1,45	1,58	08.09.2022
Brattnäsviken 5	1,9	1,83	08.09.2022
Brattnäsviken 6	1,5	1,42	08.09.2022
Brattnäsviken 7	1,5	1,67	08.09.2022
Brattnäsviken 8	1,85	1,53	08.09.2022

Kuvassa 9 on esitetty Kassorin ja Rapusvikenin lahdilta leikattuja näytepisteitä vastaavien Sentinel 2 -kuvan pikseleiden heijastusarvokäyrät. Suurimmat erot heijastusarvoissa havaittiin aallonpituuksilla 700–900 nanometriä sekä 1600 ja 2200 nanometriä. Muilla aallonpituuksilla erot olivat vähäisempiä. Suurin havaittu heijastusarvo oli pisteellä Kassor 2 noin 850 nanometrillä aallonpituudella, jolloin näytepisteen heijastusarvo oli 0,186.



Kuva 9. Kassorin ja Rapusvikenin näytepisteiden heijastuskäyrät 02.10.2020.

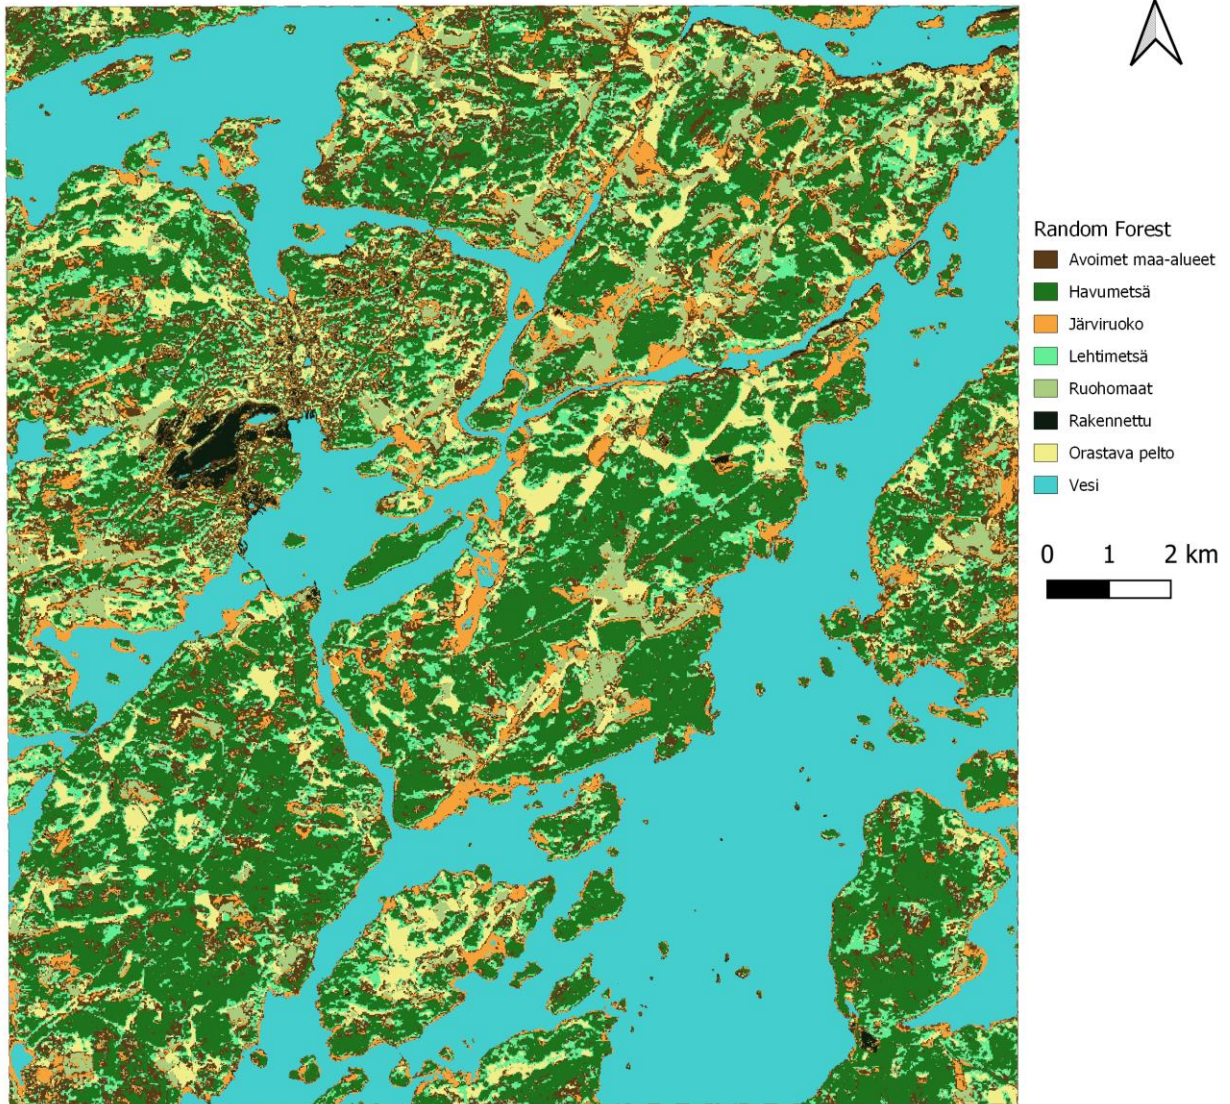
Kuvassa 10 on esitetty Brattnäsvikenin lahdelta leikattuja näytepisteitä vastaavien Sentinel 2 -kuvan pikseleiden heijastusarvokäyrät. Suurimmat erot heijastusarvoissa havaittiin aallonpituuksilla 750–900 nanometriä sekä 1600 nanometriä. Muilla aallonpituuksilla erot olivat vähäisempiä. Suurin havaittu heijastusarvo oli pisteellä Brattnäsviken 6 noin 850 nanometrillä aallonpituudella, jolloin näytepisteen heijastusarvo oli 0,356.



Kuva 10. Bratnäsviskenin näytepisteiden heijastuskäyrät 30.08.2022.

## 5.2 Ruovikoiden erottaminen satelliittikuvista ohjatulla luokittelulla

Random Forest -ohjattu luokittelu rajatulle 02.10.2020 Sentinel 2 -satelliittikuvalla onnistui kohtuullisesti. Kuvasta 11 on havaittavissa, että etenkin vesi- ja metsäalueet luokittuivat hyvin. Myös järviruovikot erottuvat kuvasta. Järviruoko kuitenkin osittain sekoittui orastaviin peltoihin ja avoimiin maa-alueihin (Taulukko 3). Muista maanpeiteluokista järviruoko erottui hyvin.



Kuva 11. 02.10.2020 Sentinel 2 -satelliittikuvalle tehdyn Random Forest -luokittelun tulokset.



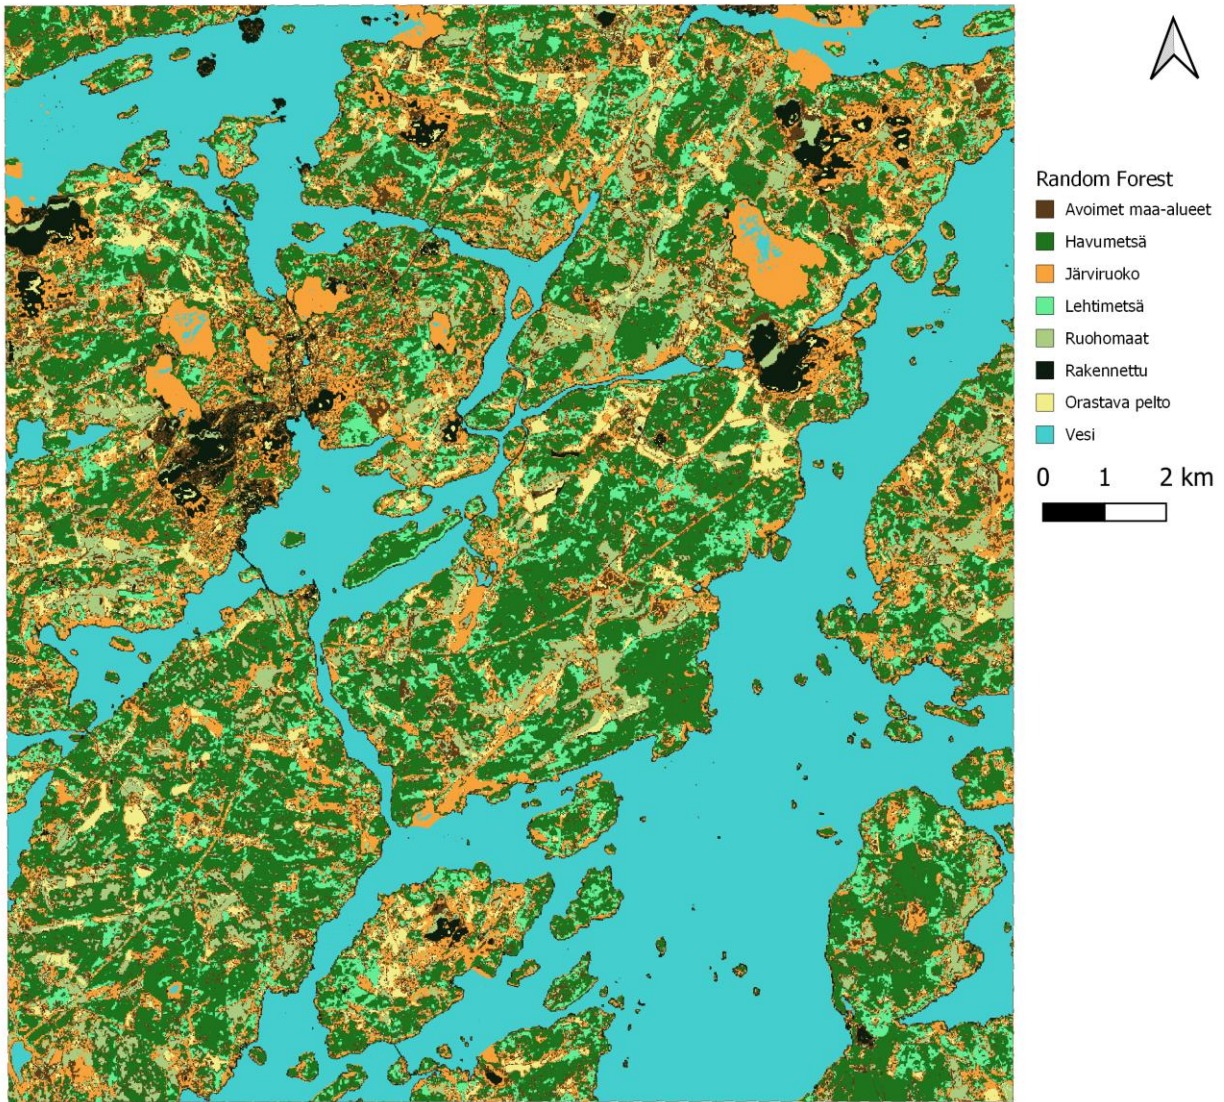
Taulukko 3. 02.10.2020 Sentinel 2 -satelliittikuvalle tehdyn Random Forest -luokittelun virhematriisi

	Referenssi- aineisto									
Luokiteltu- aineisto	Vedet	Havumetsät	Lehtimetsät	Ruohomaat, niityt	Orastavat pellot	Avoimet maa- alueet	Järviruoko	Rakennettu	Yhteensä	Käyttäjän tarkkuus
Vedet	19								19	100 %
Havumetsät		15	2			4	1		22	68,00 %
Lehtimetsät		2	9				1		12	75,00 %
Ruohomaat, niityt				1	9	4		4	18	6 %
Orastavat pellot			5	16	4				25	16,00 %
Avoimet maa-alueet			4	2	3	11	1	12	33	33,00 %
Järviruoko	1				4	3	17		25	68,00 %
Rakennettu						1		3	4	75,00 %
Yhteensä	20	17	20	19	20	23	20	19	158	
Tuottajan tarkkuus	95,00 %	88,00 %	45,00 %	5 %	20,00 %	47,00 %	85,00 %	15 %		50,00 %

Ohjattu luokittelu 30.08.2022 Sentinel 2 -satelliittikuvalle onnistui keskinkertaisesti.

Parhaiten onnistui vesialueiden luokittelu. Vesialueet erottuivat hyvin myös järviruokobiomassan keskeltä (kuva 12). Vesialueiden erottuminen ruovikosta on havaittavissa parhaiten tutkimusalueella Brattnäsvikenissä. Järviruovikoiden kohdalla tapahtui niin, että algoritmi luokitteli ruovikot ruovikoiksi, mutta luokitteli myös avoimia alueita ja ruohomaita ruovikoiksi (Taulukko 4). Kuvasta 11 on hyvin havaittavissa järviruovikoiksi luokittuneet sisämaan avoimet alueet.

Avoimien alueiden luokittuminen ruovikoiksi ei kuitenkaan haitannut tätä tutkimusta, sillä biomassanalyysia varten kuvasta rajattiin ainoastaan Brattnäsvikenin ruovikot, mutta asia tulisi haasteeksi, mikäli koko kuvalle tehtäisiin järviruovikon biomassan arviointi, jolloin ohjatun luokittelun tulokset tulisi ottaa paremmin huomioon.



Kuva 12. 30.08.2022 Sentinel 2 -kuvalla tehdyn ohjatun luokittelun tulokset esitettynä kartalla.

Taulukko 4. 30.08.2022 Sentinel 2 -satelliittikuvalle tehdyn ohjatun luokittelun virhematriisi.

	Referenssi-aineisto									
Luokiteltu-aineisto	Vedet	Havumetsät	Lehtimetsät	Ruohomaat, niityt	Orastavat pellot	Avoimet maa-alueet	Järviruoko	Rakennettu	Yhteensä	Käyttäjän tarkkuus
Vedet	19								19	100 %
Havumetsät		18	2	1			1		22	81,00 %
Lehtimetsät		2	10						12	83,00 %
Ruohomaat, niityt				1	11	1		1	14	7 %
Orastavat pellot			1	10	6	4	1	1	23	26,00 %
Avoimet maa-alueet		2	4	4	2	8	1	7	28	28,00 %
Järviruoko	1			3	1	5	17	2	29	58,00 %
Rakennettu					1	1		9	11	81,00 %
Yhteensä	20	22	17	17	21	19	20	20	158	
Tuottajan tarkkuus	95,00 %	81,00 %	58,00 %	5 %	28,00 %	42,00 %	85,00 %	45 %		55,00 %

### 5.3 Ruovikon biomassan arviointi

Kassorin ja Rapusvikenin osalta lineaarisen regressiomallin tulokset osoittavat, että siihen valitut muuttujat (taulukko 5) selittävät järviruovikon biomassan vaihtelusta 47 prosenttia. Mallissa havaittavassa pientä positiivista autokorrelaatiota. Lineaarinen regressiomalli on tilastollisesti merkitsevä (taulukko 5). Taulukossa 6 on esitetty lineaarisen regressiomallin kaava.

Taulukko 5. 02.10.2020 ja 30.09.2022 Sentinel 2 -satelliittikuvien heijastusarvoille tehtyjen lineaaristen regressiomallien ennustusprosentit sekä autokorrelaation asteet.

Tilastolliset tunnusluvut	02.10.2020	30.8.2022
R	0,686	0,972
Determinaatiokerroin (R <sup>2</sup> )	0,47	0,945
Mukautettu determinaatiokerroin	0,368	0,932
Arvion keskivirhe	25,19051	15,84771
Durbin-Watson	1,365	2,004
Selittävät muuttujat	savi, ndwi, ndvi, B2, B12, B4, B3, B5, B7, B6, dvi, B11	savi, ndwi, ndvi, B2, B12, B4, B3, B5, B7, B6, dvi, B11
Selitettävä muuttuja	Biomassa	Biomassa
P-arvo (sig.)	0,000	0,000

Taulukko 6. 02.10.2020 Sentinel 2 -satelliittikuvulle tehty lineaarinen regressiomalli

Useamman selittäjän lineaarinen regressiomalli	
Tuore biomassa	= -41,465 – 30,770 (B2) – 2276,362 (B3) + 2176,747 (B4) – 169,345 (B5) -1606,966 (B6) + 758,181 (B7) + 2503,977 (B11) -2025,601 (B12) -408,801 (NDVI) -2963,267 (DVI) + 61,217 (NDWI) + 2069,625 (SAVI)


Brattnäsvikenin lahden osalta lineaarisen regressiomallin tulokset osoittavat, että siihen valitut muuttujat (taulukko 5) selittävät järviruovikon biomassan vaihtelusta 94,5 prosenttia.

Lineaarinen regressiomalli on tilastollisesti merkitsevä (taulukko 5). Mallissa ei ole havaittavista autokorrelaatiota. Taulukossa 7 on esitetty lineaarisen regressiomallin kaava.

Taulukko 7. 30.08.2022 Sentinel 2 -satelliittikuvalle tehty lineaarinen regressiomalli

Useamman selittäjän lineaarinen regressiomalli	
Tuore biomassa	= -34,405 – 162,121 (B2) – 644,031 (B3) + 3505,643 (B4) – 683,675 (B5) -1037,162 (B6) + 887,402 (B7) – 676,215 (B11) + 3087,008 (B12) -24,171 (NDVI) + 236,686 (DVI) + 29,283 (NDWI) – 209,837 (SAVI)

Kuvassa 13 on vertailussa tutkimusalueiden näyteleikkut ja biomassa-arviot. Kuvassa havainnollistuu, kuinka vähäiset erot biomassan ja näyteleikkuiden välillä on, lukuun ottamatta näytestettä Rapusviken 1. Kassorin ja Brattnäsviken osalta erot ovat vähäisiä ja arvot sijoittuvat lähelle trendiviivaa.

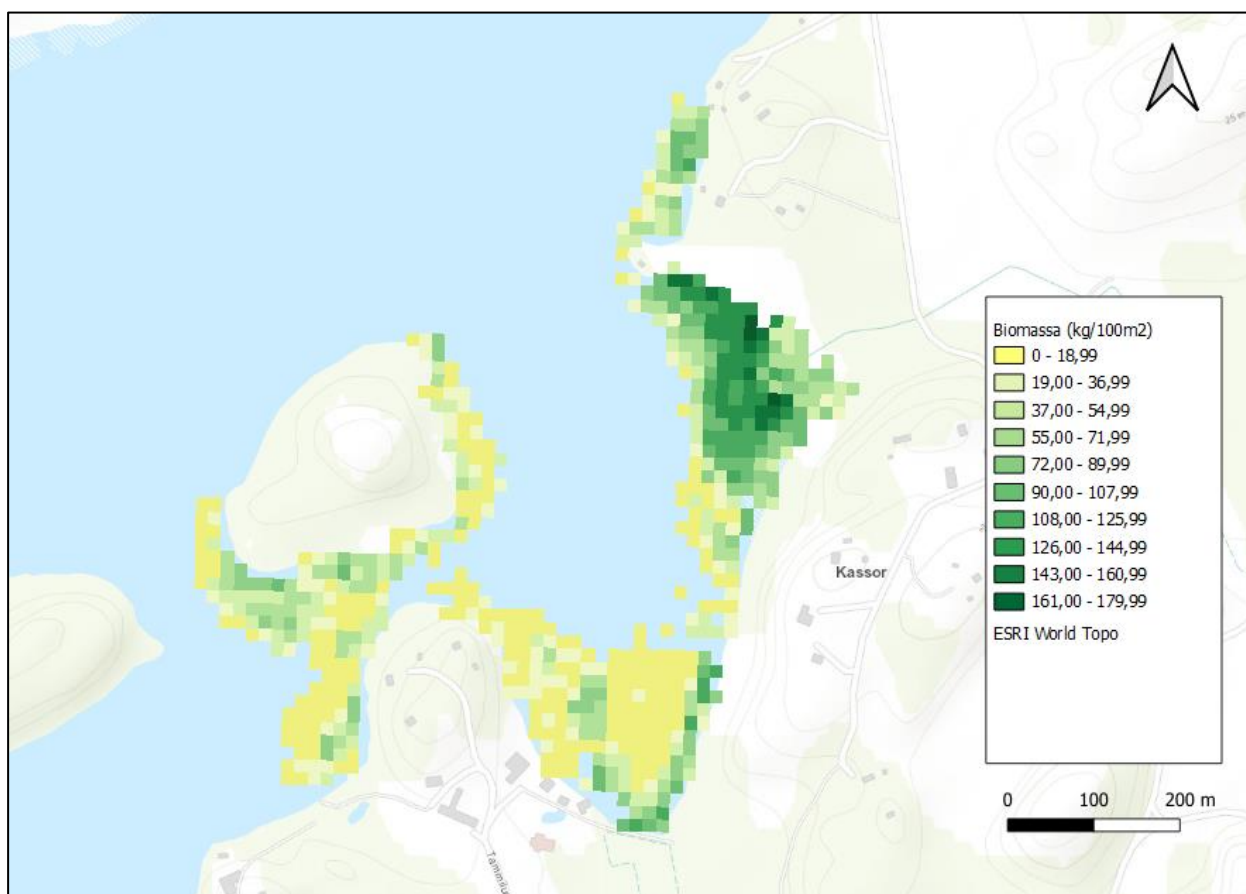


Kuva 13. Vertailussa näyteleikkut ja biomassa-arviot. B=Brattnäsviken, K= Kassor, R=Rapusviken.

#### 5.4 Biomassan alueellinen jakauma

Kuvassa 14 on esitetty järviruokobiomassan alueellinen jakautuminen Kassorin lahdella. Kartalta on havaittavissa suurta vaihtelua eri alueiden välillä. Suurimmat biomassat havaittiin lahden itäisellä reunalla lähellä maarajaa. Kassorin alueella havaittiin pienimmät biomassa-arvot. Myös kokonaisbiomassa, että keskiarvo per järviruokopikseli olivat pienimmät verrattuna muihin tutkimusalueisiin.

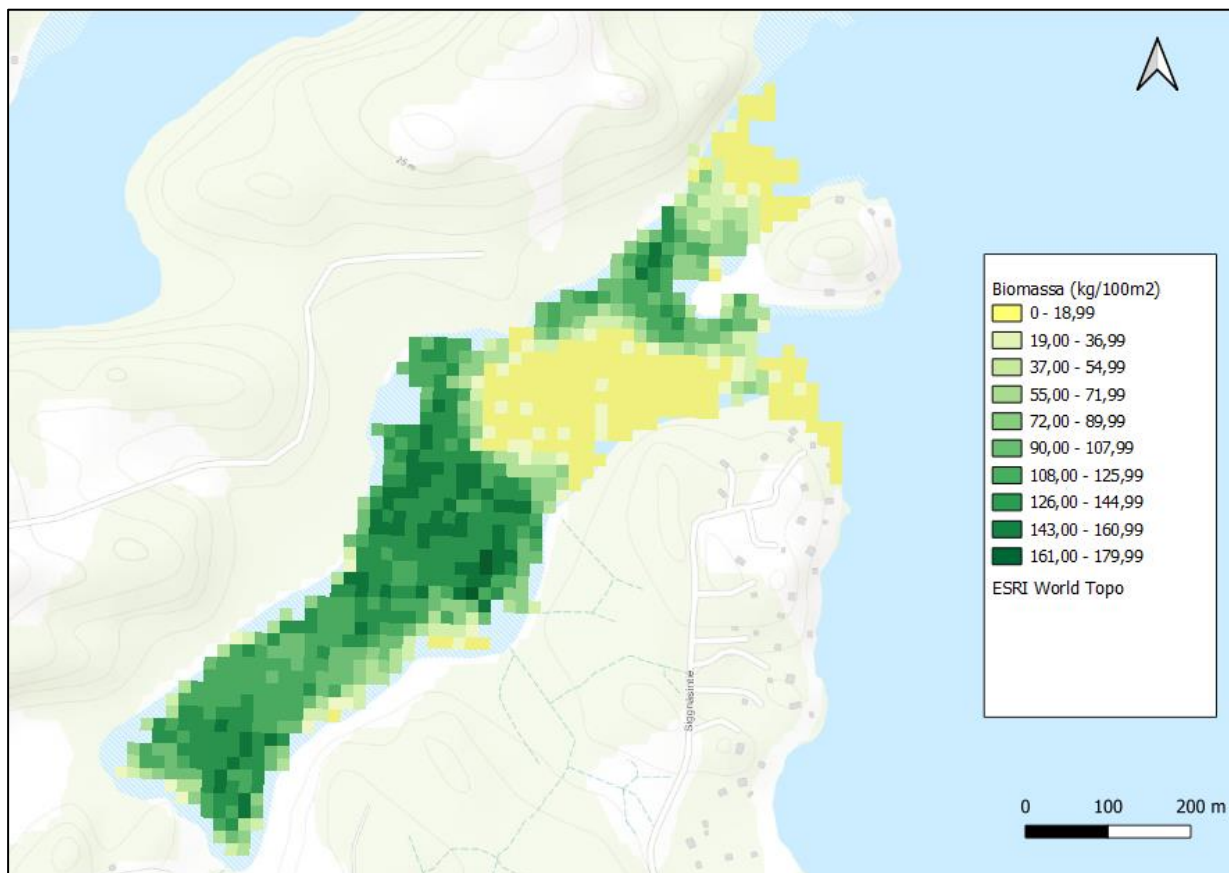
Kassorin lahden kokonaisbiomassa oli 58774 kg eli noin 59 tonnia. Keskimääräinen biomassa per aari (10 m x 10 m) oli 46 kg ja mediaani 42 kg. Järviruovikon tuore biomassa Kassorin lahdella syksyllä 2020 oli 4,61 tonnia per hehtaari. Järviruokoa oli 12,78 hehtaarin kokoisella alueella.



Kuva 14. Järviruovikon biomassa Kassorin lahdella.



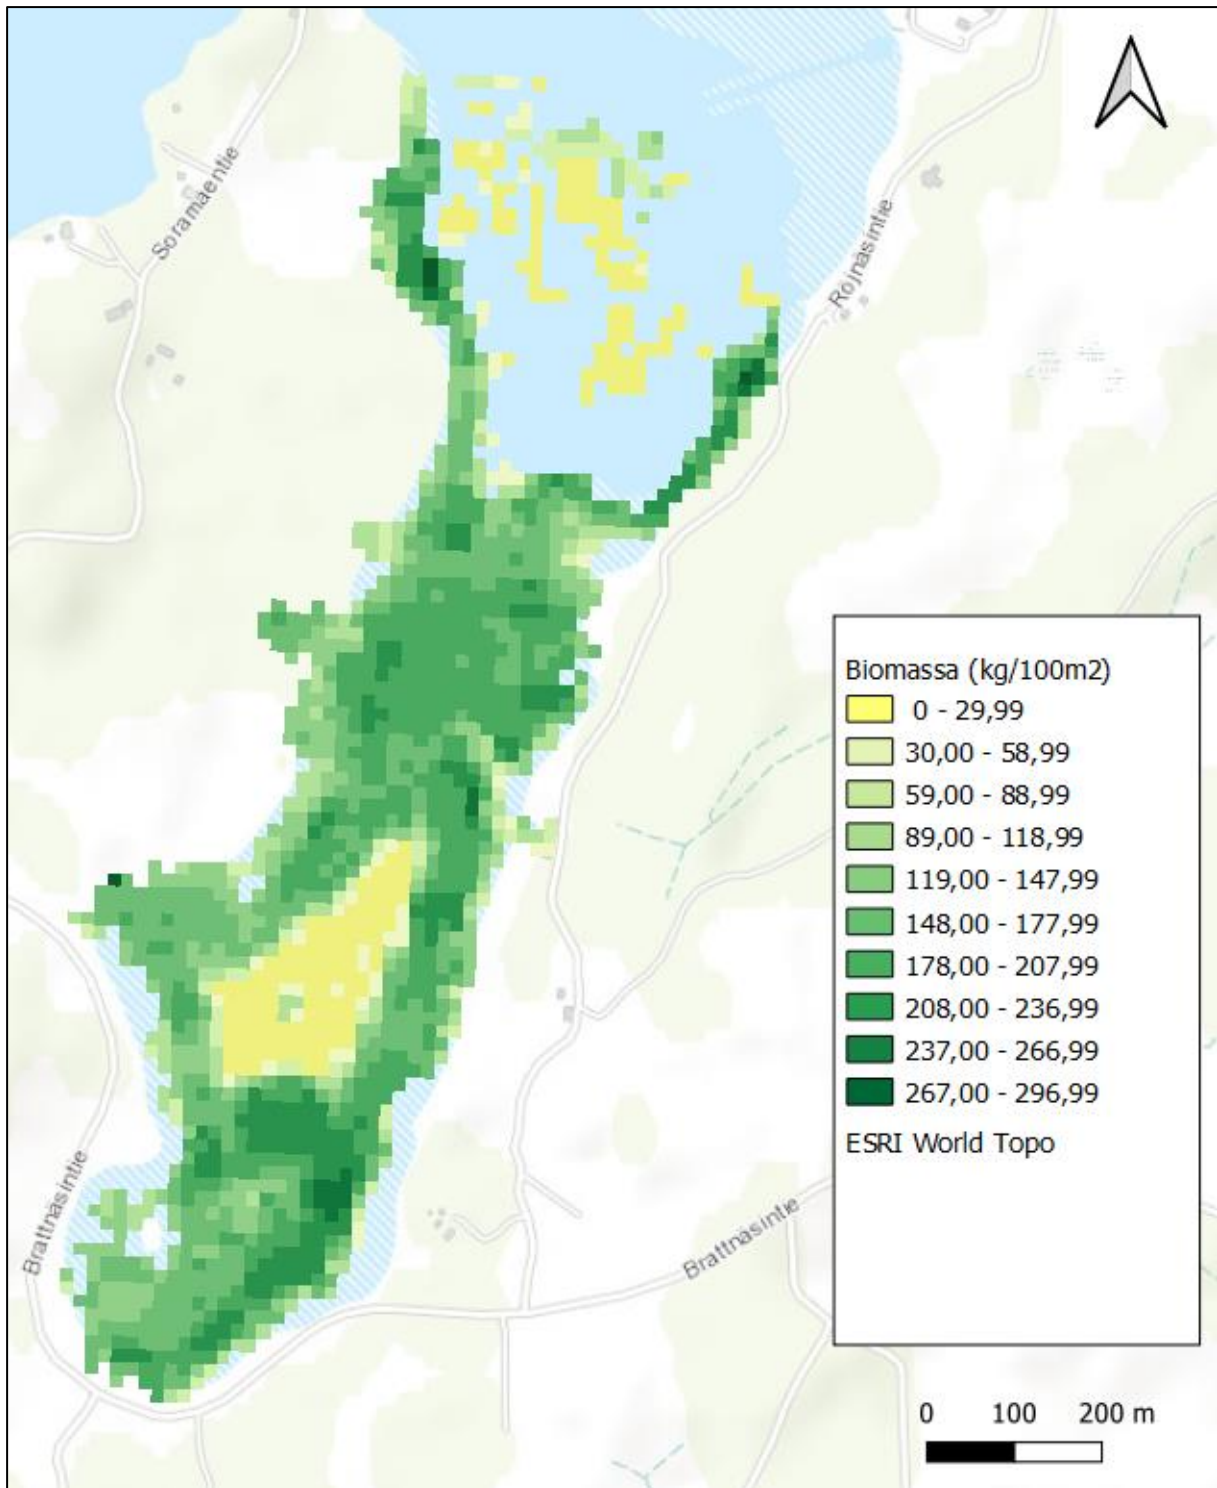
Kuvassa 15 on esitetty järviruokobiomassan jakautuminen Rapusvikenin lahdella. Kartan pikseleiden koko vastaa Sentinel 2 -satelliittikuvan pikselikokoa (10 m x 10 m). Rapusvikenin lahdella suurimmat biomassa-arvot havaittiin lahden lounaisosassa. Kokonaisbiomassa Rapusvikenin lahdella 150876 kg eli on noin 151 tonnia. Keskiarvo oli 81 kg ja mediaani 98 kg per 10 m x 10 m pikseli. Järviruovikon tuore biomassa Rapusvikenin lahdella syksyllä 2020 oli 8,14 tonnia per hehtaari. Järviruokoa oli 18,54 hehtaarin kokoisella alueella.



Kuva 15. Järviruovikon biomassa Rapusvikenin lahdella.

Kuvassa 16 on esitetty järviruokobiomassan alueellinen jakautuminen Brattnäsvikenin lahdella. Kartalta on havaittavissa suurta vaihtelua eri alueiden välillä. Suurimmat biomassat havaittiin lahden reunoilla sekä lähempänä vesirajaa. Kokonaisbiomassaksi alueelle tuli 499400 kg eli 499,4 tonnia. Keskiarvo 143 kg ja mediaani 164 kg (per 10 m x 10 m). Järviruovikon tuorebiomassa Brattnäsvikenin lahdella oli noin 14,3 tonnia per hehtaari.

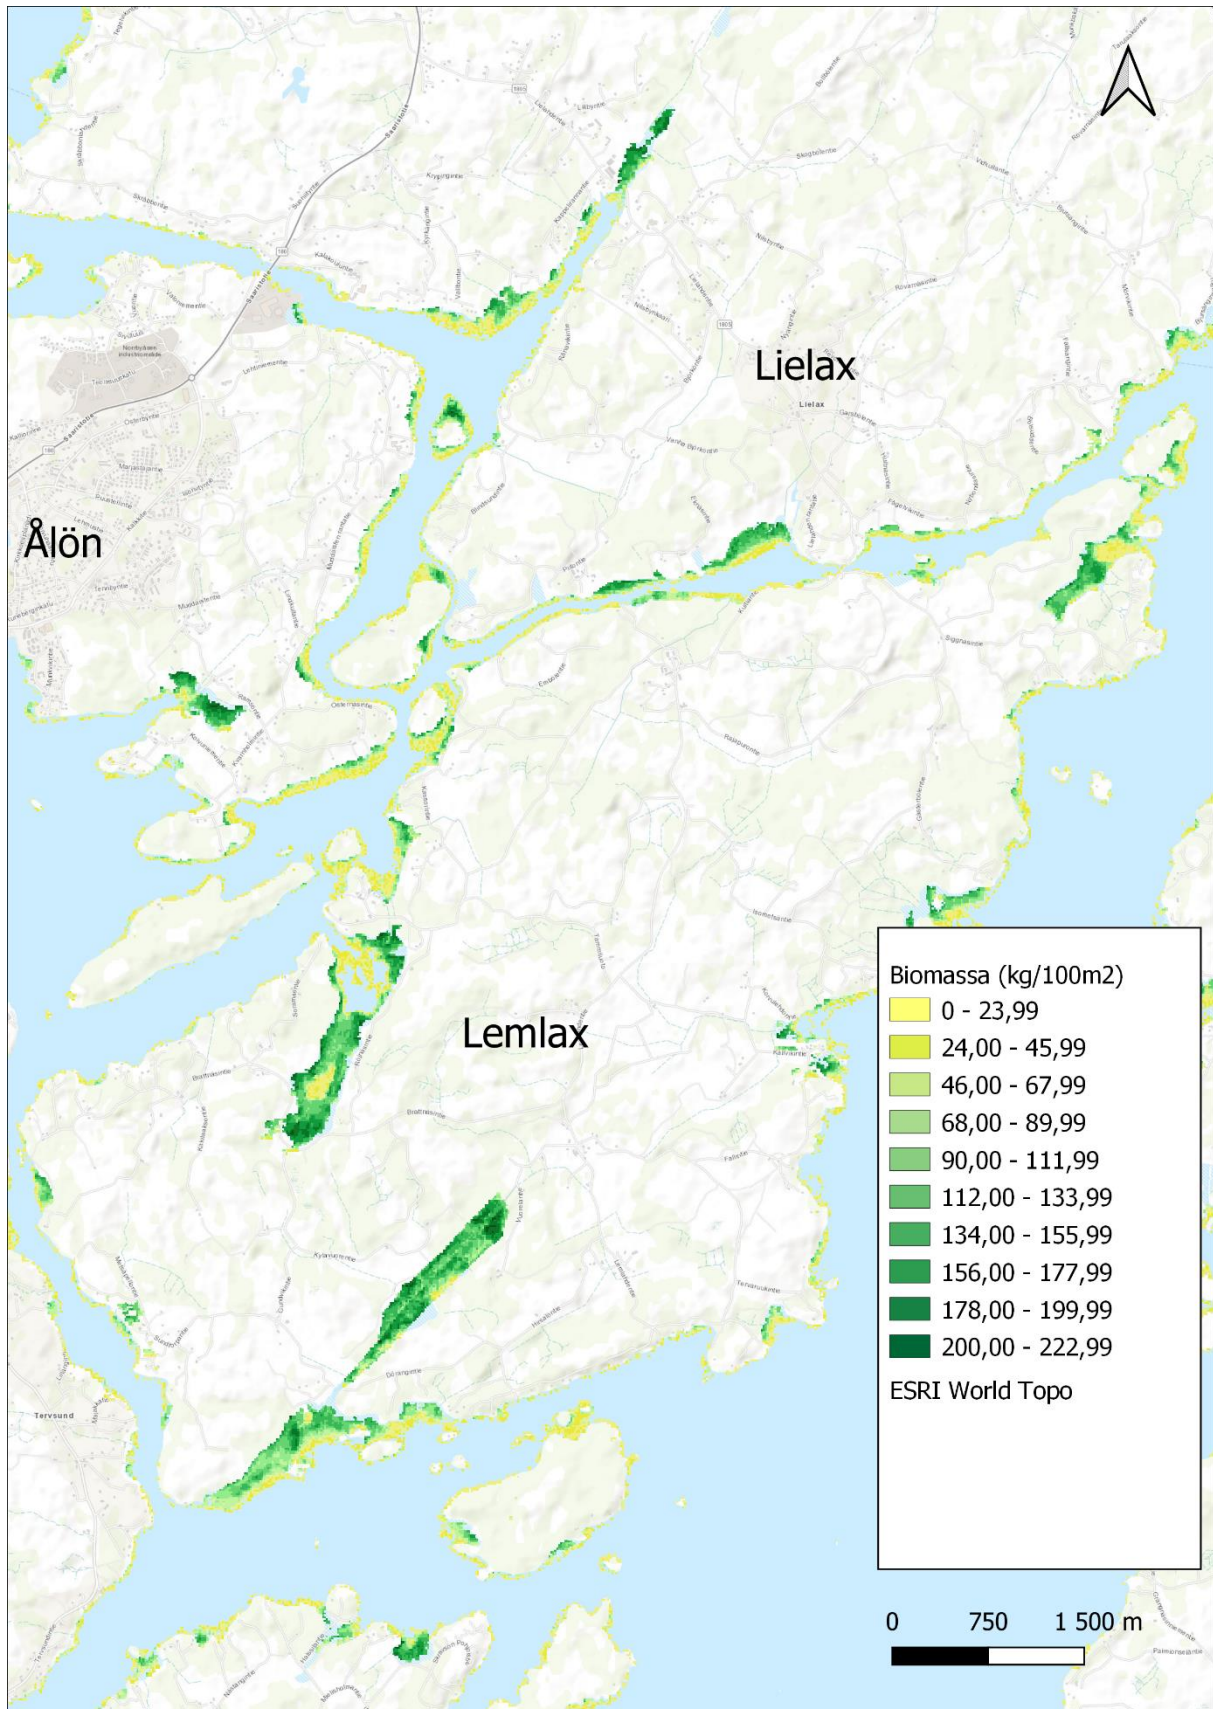




Kuva 16. Järviruovikon biomassa Brattnäsvikenin lahdella 30.08.2022.

Kuvassa 17 on esitetty Lemlahden saaren ja sen naapurisaarten järviruokobiomassa 02.10.2020. Biomassan laskennassa on hyödynnetty samoja menetelmiä kuin tutkimusalueilla. Tällä analyysillä demonstroidaan menetelmän soveltuvuutta suuremmille alueille. Analyysi tehtiin isommalle tutkimusalueelle, joka on esitetty kuvassa 3. Biomassa-arvion mukaan koko tutkimusalueella (kuva 3) järviruokoa on 5985224 kilogrammaa eli 5985 tonnia. Järviruovikon tuore biomassa koko tutkimusalueella oli 2020 noin 6,6 tonnia per hehtaari. Isommalla tutkimusalueella järviruokoa on 890 hehtaaria.

Kartalle (kuva 17) on kuitenkin visualisoitu vain Lemlahden saari, sillä sieltä oli tiedossa näyteleikkuiden biomassatiedot. Lemlahden saaren ja sen naapurisaarten alueella (kuva 20) on järviruokoa 3557481 kilogrammaa eli 3557 tonnia. Mikä on 7,8 tonnia per hehtaari märkää järviruokobiomassaa. Keskimääräinen biomassa per Sentinel-kuvan pikseli on 67 kg. Maksimiarvo per Sentinel 2 -pikseli on 222 kg. Kuvan alueella järviruokoa on 455 hehtaaria. Suurimmat biomassat Lemlahden saaren suurissa ruovikoissa; Brattnäsviken, Rapusviken ja Kopparviken.



Kuva 17. Lemlaxin saaren ja naapurisaarten järviruokobiomassa 02.10.2020.

## 6 Pohdinta

### 6.1 Biomassan arviointi satelliittikuvista

Tässä tutkimuksessa käytettiin ohjattua luokittelua ja useamman selittäjän lineaarista regressiomallia järviruovikon biomassan arviointiin Sentinel 2 -satelliittikuvista. Biomassa-arvioita verrattiin tutkimusalueilta leikattuihin näyteleikkuarvoihin. Tutkimuksessa arvioitiin tuoreen eli märän biomassan määrää tutkimusalueilla. Usein ruoko kuivataan jatkotarkoitusta varten. Nämä arvot saadaan vähentämällä veden määrä biomassarvioista. Koska tutkimusalueiden ruo'on kosteusprosentti oli noin 40-50 prosenttia (Tornikoski & Simi-Virahsawmy 2020), niin tutkimusalueiden kuiva biomassa on noin puolet analyysin arvioimista märän biomassan arvoista.

Heijastusarvoja tarkasteltaessa huomataan suuri vaihtelu satelliittikuvien välillä. Syyskuun kuvassa näkyy vielä selkeä kasvu punaisilla aallonpituuksilla ja infrapunakanavilla, jotka ovat tunnusomaisia piirteitä kasvuvaiheessa olevalle ruovikolle (Tuominen & Lipping 2016). Lokakuussa kellastuneen ruovikon ikääntyessä, heijastuskäyrä on tasaisempi ilman selkeästi erottuvia heijastusarvoja.

Käyrän tasaisuus johtuu kuolleen biomassan määrästä kasvustosta. Saman ovat huomanneet myös Tuominen & Lipping (2016), jotka tutkivat Olkiluodon ruovikoiden heijastuskäyrien ajallista jakaumaa. Myös Gilmore ym. 2008 tutkimuksessa havaittiin, että ruovikoiden heijastusspektri infrapunakanavilla laskee loppusyksystä. Heidän tutkimuksissaan korkeimmat heijastusarvot havaittiin 1.8 sekä 27.6 ja pienimmät 1.10 ja 27.5 (Gilmore ym. 2008).

Voidaan siis todeta, että parhaimmat ajankohdat ruovikoiden erottumiseen muusta kasvillisuudesta osuvat kesäkuu-syyskuu väliselle ajanjaksolle, sillä loppusyksyn kuvia on hyödynnetty onnistuneesti useissa järviruovikon levinneisyyttä tutkineissa tutkimuksissa (muun muassa Onojeghuo & Blackburn 2016; Abeysinghe ym. 2019; Rupasinghe & Chow-Fraser 2019).

Ohjatun luokittelun tulokset olivat heikommat kuin muutamissa aikaisemmissa tutkimuksissa, jossa on hyödynnetty Random Forest -analyysiä järviruovikon luokitteluun satelliittitutkimuksissa (muun muassa Davranche ym. 2010; Zhao ym. 2022). Tässä tutkimuksessa tuottajan tarkkuus molemmissa kuvissa oli järviruovikon osalta 85 prosenttia ja

käyttäjän tarkkuus 68 ja 58 prosenttia. Menetelmän tulokset olivat kuitenkin kohtuulliset ja sen avulla saatiin rajattua analyysia varten tarvittut järviruovikot hyvin.

Erityisesti niityt sekoittuivat sellaisiin ruokoesiintymiin, joissa järviruokoa kasvaa vallitsevana lajina. Tämä sekoittuminen on havaittu myös aikaisemmissa tutkimuksissa (Stratoulia ym. 2015). Luokittelussa havaittiin myös orastavien peltojen ja niittyjen sekoittumista keskenään. Tässä havaittavissa vuodenaikaisuus. Loppusyksystä niittyjen kasvillisuudessa ei ole niin paljon lehtivihreää, jotta se olisi helposti erotettavissa orastavista pelloista, jotka ovat samanvärisiä kuin kellastunut ruoko. Näiden luokkien sekoittuminen on havaittu myös aikaisemmassa tutkimuksessa (Stratoulia ym. 2015, Doughty ym. 2021).

Veden ja pohjakasvillisuuden vaikutusta tuloksiin on hankalaa arvioida. Mikäli ruokokasvillisuus on korkeaa ja tiheää, niin todennäköistä on, että pohjakasvillisuus ei vaikuta tuloksiin, sillä auringonvalo ei läpäise ruokokasvustoa. Vesirajassa, jossa ruokokasvusto on harvempaa, auringon valo läpäisee enemmän vesipintaa, joten vesirajassa on mahdollista, että satelliitti kartoittaa myös pohjakasvillisuutta. Syvyys, josta pohjakasvillisuutta on mahdollisuus kartoittaa satelliittikuvista, vaihtelee paljon (Wilson ym. 2022). Se riippuu veden optisista ominaisuuksista. Erittäin sameassa vedessä kartoitusyvyys on maksimissaan metrin, mutta jopa 30 metriä kirkaassa vedessä (Wilson ym. 2022). Kuitenkin esimerkiksi Brattnäsvikenin vesi oli tutkimushetkellä niin sameaa, että mahdollinen pohja- tai vesikasvillisuus tuskin näkyisi satelliittikuvissa.

Ohjatun luokittelun onnistumisen vertaileminen muihin tutkimuksiin, on hankalaa, sillä esimerkiksi Kiinassa (Zhao ym. 2022) ja Ranskassa (Davranche ym. 2010) on erilaiset tutkimusalueet ja maankäyttöluokat kuin Paraisilla, jossa on paljon maataloutta. Esimerkiksi Kiinassa tehdyssä tutkimuksessa järviruokoa esiintyi suurella kosteikkoalueella, jossa se ei ollut vallitsevana lajina. Tutkimusalueilla ei ollut peltoja, johon järviruoko olisi voinut sekoittua (Zhao ym. 2022).

Ohjattu luokittelu ja järviruovikon levinneisyyden kartoittaminen onnistuivat kuitenkin hieman paremmin kuin Pitkäsen (2006) suuriresoluutioisille Landsat-kuville tekemät luokittelut. Pitkänen (2006) havaitsi Etelä-Suomessa tehdyssä tutkimuksessaan samoja luokitteluongelmia kuin tässä tutkimuksessa. Osa rannan lähellä sijaitsevista kapeista ruovikkovöistä jää luokittelematta ja osa niittyalueista luokituu ruovikoiksi.

Lineaarisen regressiomallin tulokset osoittavat, että valitut kasvillisuusindeksit ja satelliittikanavien heijastusarvot soveltuvat järviruokobiomassan arviointiin. Kaikkiin malleihin, niin koko tutkimusalueelle kuin pienemmille alueille, valikoituivat samat satelliittikuvakanavat ja kasvillisuusindeksit (taulukko 5), mikä korostaa valittujen muuttujien sopivuutta järviruovikoiden biomassan arviointiin Suomen olosuhteissa. Lineaarisen regressiomallin tulokset eli biomassa-arviot ovat vertailukelpoisia aikaisempiin tutkimuksiin nähden. Suomen olosuhteissa mallien tulokset olivat paremmat kuin aikaisemmissa maailmalla tehdyissä tutkimuksissa (Li ym. 2019; Zhao ym. 2022), vaikka mallien selitysasteet jäivät pienemmiksi kuin Kiinassa tehdyssä tutkimuksessa (Zhao ym. 2022).

Biomassa-arviot ovat todella lähellä näyteleikkuiden biomassa-arvoja. Onnistumisprosentti oli lähes 89 prosenttia. Ainoastaan Rapusviken 1 eroaa selkeästi muista. Sen biomassa-arvio onnistui 27 prosenttisesti, ja siinä oli parin kilon eroavaisuus. Muiden näytepisteiden osalta erot olivat alle 500 grammaa. Myöskään aikaisemmissa tutkimuksissa ei olla päästy täysin samoihin arvoihin verratessa näyteleikkuita biomassa-arvioon, mutta samankaltaisiin tuloksiin ja onnistumisprosentteihin ovat päässeet muun muassa Zhao ym. 2022 sekä Li ym. 2019.

Biomassa-arviot vastaavat aikaisempia Suomessa tehtyjä tutkimuksia ja jäävät niiden viitearvojen sisään (Pitkänen 2006; Ikonen & Hagelberg 2007b). Vuonna 2006 Hirvensalon ja Salon alueella tehdyssä tutkimuksessa havaittiin järviruovikon kuivabiomassan vaihtelevan keskimääräisesti 2,5-12 tonnia per hehtaari (t/ha) välillä (Ikonen & Hagelberg 2007b). Tässä tutkimuksessa järviruon märkäbiomassa vaihteli 4,61-14,3 (t/ha) välillä. Kuivabiomassa olisi tästä noin puolet.

Tutkimus vastaa aikaisempien tutkimuksien ajatukseen siitä, että siellä missä järviruoko kasvaa vallitsevana lajina, on lajilla myös suurempi biomassa (Zhao ym. 2022). Tiheässä ruokokasvustossa kasvaa monenlaisessa kasvuvaiheessa olevaa ruokoa, jotka erottuivat analyysissä hyvin toisistaan, vaikka järviruokokasvustolla on useimmiten kompleksinen mosaiikkimainen rakenne eikä kasvusto ole homogeeninen. Tiheänä kasvustoina kasvava järviruovikon heijastuskäyrät ovat spektraalisesti puhtaampia, sillä niihin ei sekoitu muiden kasvien heijastusta (Chow-Fraser & Rupasinghe 2021).

## 6.2 Epävarmuustekijät

Ohjatun luokittelun tulosten epävarmuustekijät riippuvat ohjatun luokittelun tekijästä, ja siitä kuinka tarkasti ohjattu luokittelu on tehty. Mahdollisimman tarkkaan luokittelun tulee käyttää paljon aikaa ja heijastusarvojen vertailuja keskenään. Näin tehtiin tässäkin tutkimuksessa. Luokittelussa käytettiin vain kahdeksaa luokkaa, sillä aikaisemmissa tutkimuksissa on havaittu, että liian monet luokat voivat heikentää luokittelun laatua (Abeysinghe ym. 2019).

Tulokset kuitenkin osoittavat, että järviruovikon ja vesialueiden luokittelut onnistuivat parhaiten, mutta muissa luokissa oli paljon eroja onnistumisen osalta. Vaikka ohjatun luokittelun tulokset olivat matalat, niin huomioitavaa kuitenkin on, että tutkimuksessa keskityttiin ainoastaan järviruokoluokkaan sekä tietoon siitä, kuinka hyvin tutkimukseen valittu Random Forest -algoritmi onnistuu erottamaan ruovikot muusta kasvillisuudesta.

Epävarmuustekijöinä tutkimuksessa on näyteleikkuupisteiden sijainti sekä paino. Brattnäsvikenin näyteleikkuiden sijaintidatan olen kerännyt itse, mutta Kassorin ja Rapusvikenin leikkuiden osalta olen ainoastaan nähnyt, millaista GPS-laitetta ammattikorkeakoulun henkilökunta käytti, ja tiedän, että pisteet on jälkikäteen siirretty ilmakuuvan perusteella paremmin näyteleikkuuta vastaavaan kohtaan. Joten tämä pisteiden käsin siirtäminen voi aiheuttaa heittoja näiden tutkimusalueiden kohdalla. Kassorin ja Rapusvikenin näyteleikkuiden biomassat on punnittu elektronisella omenavaa'alla. Kun taas Brattnäsvikenin järviruokojen punnitus tapahtui Tammiluodon viinitilan antiikkisella omenavaa'alla, jonka tarkkuus ei ollut paras mahdollinen vain on mahdollista, että punnitut arvot heittävät noin 200 grammaa.

Sentinel 2 -satelliittikuvan sekapikselit aiheuttavat myös epävarmuustekijöitä tutkimukseen. Sentinel 2 -satelliittikuvan pikselin koko on 10 x 10 metriä eli yhden pikselin alueelle voi osua monenlaisia maanpeitteitä. Tällöin pikselin heijastusarvo on keskiarvo näiden maanpeiteluokkien heijastuksista ja aiheuttaa häiriötä analyysiin. Ruovikkoalueiden pienempi ympäristövaihtelu voi jäädä huomaamatta näin suurella resoluutiolla, sillä osa tutkimusalueen ruovikoista on kapeita ruovikkovöitä rannan läheisyydessä. Kuitenkin resoluutio on parempi kuin mitä saavutettaisiin esimerkiksi Landsat-satelliittikuvilla (Pitkänen 2006). Kuitenkin tässä tutkimuksessa Sentinel 2 -satelliittikuvan tarkkuus on arvioitu riittäväksi, sillä tarpeen oli paremmin arvioida vain hyötykäyttöön soveltuvat isoimmat ruovikot.

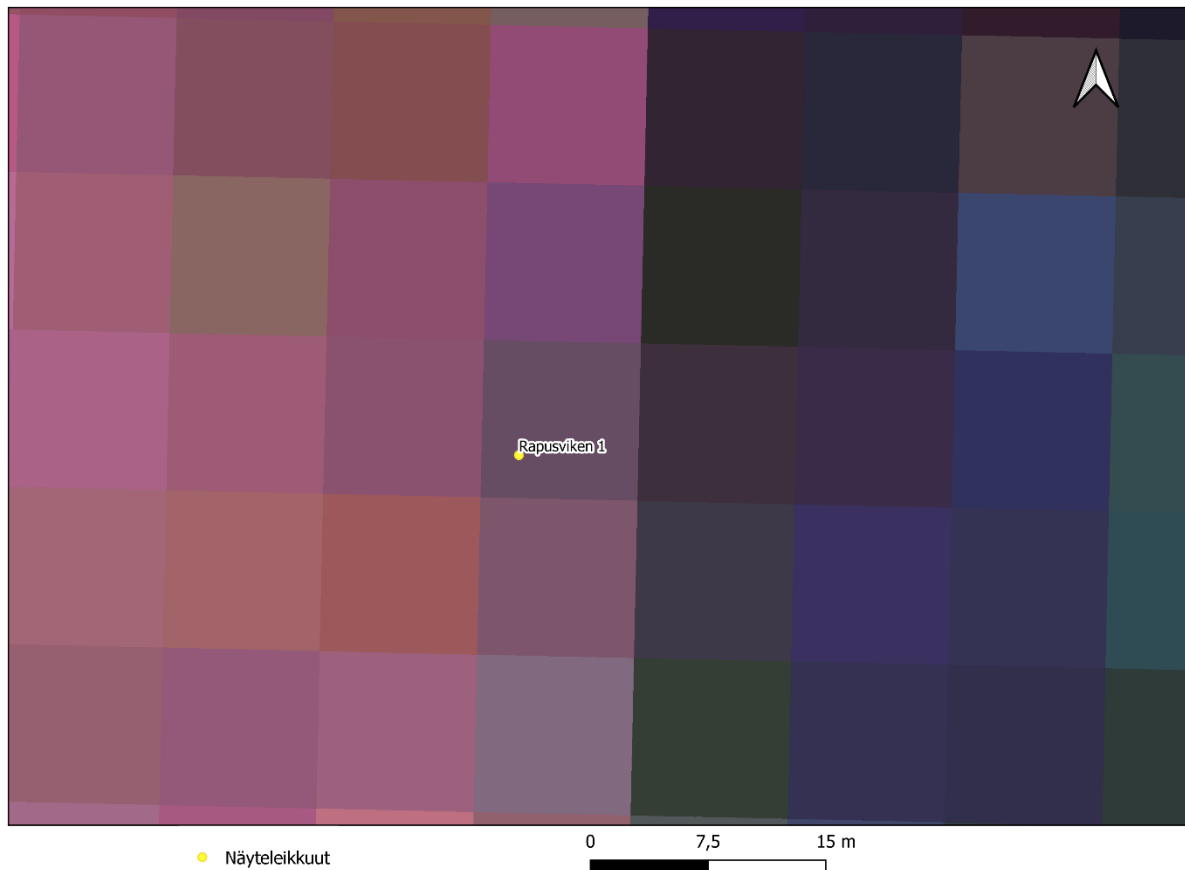


Vesialueilla voi myös esiintyä pieniä mosaiikkimaisia ruokolaikkuja, joilla on pieni biomassa. Nämä kuitenkin analyysien perusteella luokittuivat kohtuullisesti Sentinel 2 -satelliittikuvasta. Tämä mosaiikkimaisten laikkujen erottumisen hankaluus on havaittu aikaisemmissakin tutkimuksissa. Esimerkiksi Doughty ja muut (2021) huomasivat vertaillessaan tarkkoja dronekuvia Landsat-kuviin, että spatiaalisen resoluution kasvaessa myös kosteikoiden luokittelun tarkkuus heikkeni.

Veden vaikutuksen lisäksi on huomioitava myös muut mahdolliset sekapikselit analyysissä, ja pohdittava sitä, kuinka hyvin satelliittikuvan pikseli edustaa ympäristöään. Kuinka nopeasti ruokobiomassa vaihtuu ruovikon sisällä. Onko ruovikossa esimerkiksi eläinten reittejä tai muuten esimerkiksi tuulen tai myrskyjen kasaamaa ruokoa. Esiintyykö ruovikossa muuta kasvillisuutta ruo'on seassa vai sijaitseeko ruovikoiden reunoilla metsäalueita tai peltoa, kuten esimerkiksi Brattnäsvikenin tapauksessa.

Tässä tutkielmassa eniten häiriintyivät sellaiset pikselit, joissa on sekä vettä, että ruokoa. Tällaiset pikselit sijaitsevat ruovikoiden reunalla vesirajassa, kuten Rapusviken 1 (kuva 18). Rapusviken 1 näytepiste sijaitsee aivan ruovikon vesirajassa, sillä se on leikattu veneestä. Tässä tapauksessa veden osuus pikselistä voi vaikuttaa siihen, että biomassa-arvion ja näyteleikkuun välillä on suurin ero suhteessa muihin tutkimuspisteisiin.

Rapusviken 1 -tapauksessa biomassa-arvio on suhteessa näyteleikkukseen pienempi kuin muiden näytepisteiden. Selitys erolle voi olla se, että näytepisteellä on pienempi vesiprosenttiosuus biomassasta kuin muilla näyteleikkuupisteillä (Tornikoski & Simi-Virahsawmy 2020). Mahdollista on myös näytepisteen väärä sijainti tai veden määrän suuri osuus pikselissä. Sekä kuinka hyvin pikseli edustaa ympäristöään.



Kuva 18. Rapsuviken 1 sijainti, 02.10.2020 Sentinel 2 -satelliittikuvan alueella.

Vaikka tutkielman aineistoon ja analyysien tulkintaa sisältyy paljon mahdollisia virhelähteitä, on tutkielman tulos kuitenkin käyttökelpoinen ja sovellettavissa monenlaisiin käyttötarkoituksiin. Lopulliset biomassa-arviot kuvaavat järviruovikon biomassan määrää satelliittikuvan oton ajankohtana, josta biomassamäärät ovat vaihtuneet. Esimerkiksi Brattnäsvikenin ruovikko on suurimmalta osin leikattu syyskuun 2022 loppupuolella.

### 6.3 Jatkotutkimusideat

Järviruovikon biomassan arviointi satelliittikuvista vaatii lisätutkimuksia. Kiinnostavaa olisi tutkia biomassan vaihteluita eri vuodenaikoina, kuten keväällä tai kesällä, jolloin järviruoko sisältää paljon lehtivihreää. Myös talviajan tarkastelu toisi lisäarvoa tutkimukselle, jos järviruokoa alettaisiin leikata talviaikaan jään pinnalta. Talvella veden pinnan peittävä jää heijastaa auringonsäteilyä enemmän kuin avovesi kesällä ja loppusyksystä.

Myös pidemmän välin aikasarjan tarkastelu Suomen osalta voisi auttaa mallintamaan järviruovikon leviämistä tulevaisuudessa. Pidemmän aikasarjan tutkimuksia on tehty muualla maailmalla, jossa on havaittu järviruovikon levinneen runsaasti viime vuosikymmenien aikana (Davranche ym. 2010).

Suurempi tutkimusalue mahdollistaisi tarkemman biomassavertailun eri alueiden välillä. Kiinnostavaa olisi tehdä analyysi etenkin koko Saaristomeren alueelle, jossa aikaisempien tutkimusten mukaan järviruokoa on paljon (Pitkänen 2006). Ruovikon määrä alueella vain kasvaa.

Ruovikon rakenteellisten erojen, kuten pituuden ja korren halkaisijan tutkimus toisi lisätietoa siitä, millaiset biologiset piirteet vaikuttavat ruovikon biomassaan. Lisäksi ruovikon vesipitoisuuden tarkastelu tulevaisuudessa on tärkeää, jotta ymmärretään sen vaikutus ruovikon heijastusarvoihin.

Testaamalla muita algoritmeja voidaan päästä vielä tarkempiin tuloksiin biomassan mallintamisessa. Etenkin dronekuvien avulla on päästy tarkkoihin tuloksiin ruovikon levinneisyyden mallintamisessa. Monet tutkimukset ovat todenneet, että objekteihin perustuvat luokittelut toimivat paremmin kuin pikseleihin perustuvat (Abeyasinghe ym. 2019).

Tärkeää on myös pohtia, mikä tarkkuus palvelee käyttötarkoitusta. Kannattaako järviruoko' on hyödyntäjien käyttää dronea ruovikoiden kuvaukseen vai riittääkö heidän käyttötarkoituksiinsa karkeampi satelliittikuva, joka otetaan noin 5-10 päivän välein 10 metrin resoluutiolla. Ilmakuvaus dronella ja kuvien edelleen prosessointi on aikaa vievä menetelmä järviruovikon biomassan määrittämiseksi.

Dronekuvaukseen vaadittavat kalustot ovat kalliita. Useimmat kuvaprosessointimenetelmät, vaativat lisenssin, joka on kallis investointi. Prosessoimiseen ja kuvien liittäminen paikkatieto-ohjelmistoon vaatii käyttäjältään osaamista. Huomioitavaa dronekuvista on, että

niillä ei pääse samaan spektraaliseen resoluutioon, jonka satelliittikuvat mahdollistavat. Mikäli dronen kyytiin laittaisi hyperspektrikameran niin silloin tulokset varmasti olisivat paremmat kuin satelliittikuvan tulokset. Näin on arvioitu aikaisemmissa tutkimuksissakin (Abeyasinghe ym. 2019; Li ym. 2019). Dronekuvia on yhdistetty latvusmalleihin (*canopy height model*), jotta ruovikon korkeuden mallintaminen on mahdollistettu (Anderson et al. 2021).

Yhdistämällä näytteenotto ja ilmakehuus hyperspektrikameralla voidaan saavuttaa tarkka biomassalaskelma. On kuitenkin kyseenalaista, että menetelmä olisi optimaalinen pienyrittäjälle aikaresurssien ja tuottavuuden kannalta. Kuitenkin tapauksessa, jossa pyritään saamaan mahdollisimman paljon tietoa ruovikoiden biomassasta reaaliaikaisesti, olisi järkevämpää hyödyntää esimerkiksi webkarttatyypistä ratkaisua, jossa pohjalla käytettäisiin mahdollisimman uusinta ilmaiseksi saatavaa satelliittikuva-aineistoa, johon olisi lisätty algoritmi, joka laskee biomassan mahdollisimman tarkasti. Ruo'on keruusta kiinnostuneelle yrittäjälle varmasti riittää summittainen tieto siitä, kuinka paljon ruokoa alueella on ja onko ruo'on leikkaaminen alueelta kannattavaa.

## 7 Johtopäätökset

- Elokuun loppupuolen ja lokakuun alun Sentinel 2 -satelliittikuvista voidaan arvioida järviruokobiomassa Etelä-Suomen olosuhteissa kohtuullisen tarkasti.
- Random Forest -algoritmi soveltuu järviruovikoiden levinneisyyden arviointiin. Onnistumisprosentti vaihteli 58-85 prosentin välillä. Onnistumisprosenttiin vaikuttaa orastavien peltojen sekoittuminen järviruovikkoon erityisesti syksyllä.
- Useamman selittäjän lineaarinen regressiomalli soveltuu järviruovikoiden biomassan arviointiin. Lineaarisen regressiomallin ennustusaste 2020 kuvalla oli 47 prosenttia ja 2022 kuvalle 94,5 prosenttia.
- Biomassa-arviot lähellä näyteleikkuita, onnistumisprosentti 89 prosenttia. Suurin ero pisteessä Rapusviken 1, jonka onnistumisprosentti oli 27 prosenttia.
- Järviruo'on biomassa koko tutkimusalueella 2020 oli keskimäärin 6,6 tonnia per hehtaari. Vuonna 2020 Kassorin lahdella 4,61 tonnia per hehtaari ja Rapusvikenin lahdella 8,14 tonnia per hehtaari. Brattnäsvikenin lahdella vuonna 2022 14,3 tonnia per hehtaari.
- Biomassa-arviot ovat hyvin linjassa aikaisempien tutkimusten kanssa.

## Kiitokset

Lämpimät kiitokset ohjaajalleni Harri Tolvaselle avusta, tuesta ja yhteistyöstä graduprosessissa. Kiitokset Turun ammattikorkeakoulun henkilökunnalle yhteistyöstä gradun teon aikana. Kiitokset myös gradun aineistoista ja avusta aineiston keruussa Brattnäsvikenin lahden osalta. Kiitokset perheelle ja ystäville tuesta gradun teon aikana.

## Lähteet

- Abeysinghe, T., Simic Milas, A., Arend, K., Hohman, B., Reil, P., Gregory, A. & Vazquez-Ortega, A. (2019) Mapping invasive *Phragmites australis* in the Old Woman Creek estuary using UAV remote sensing and machine learning classifiers. *Remote Sensing* 11(11) 1380. <http://dx.doi.org/10.3390/rs11111380>
- Adam, E., Mutanga, O., & Rugege, D. (2010) Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. *Wetlands Ecology and Management* 18 281–296. DOI 10.1007/s11273-009-9169-z
- Alijoki, T. (2013) *Korret poikki ja pinoon. Järviruoko ja sen korjuutoiminnan edellytykset Suomessa*. Turun Ammattikorkeakoulun raportteja 161. <https://julkaisut.turkuamk.fi/isbn9789522163721.pdf>
- Anderson, C.J., Heins, D., Pelletier, K.C., Bohnen, J.L. & Knight, J.F. (2021) Mapping invasive *Phragmites australis* using unoccupied aircraft system imagery, canopy height models, and synthetic aperture radar. *Remote Sensing* 13 3303. <https://doi.org/10.3390/rs13163303>
- Andersen, J.H., Carstensen, J., Conley D. J., Dromph, K., Fleming-Lehtinen, V., Gustafsson, B.G., Josefson, A.B., Norkko, A., Villnäs, A. & Murray, C. (2017) Long-term temporal and spatial trends in eutrophication status of the Baltic Sea. *Biological Reviews* 92 135–149. doi: 10.1111/brv.12221
- Davranche, A., Lefebvre, G. & Poulin, B. (2010) Wetland monitoring using classification trees and SPOT-5 seasonal time series. *Remote Sensing of Environment* 114 552–562. <http://dx.doi.org/10.1016/j.rse.2009.10.009>
- Doughty, C.L., Ambrose, R. F., Okin, G. S. & Cavanaugh, K.C. (2021) Characterizing spatial variability in coastal wetland biomass across multiple scales using UAV and satellite imagery. *Remote Sensing in Ecology and Conservation* 7 411–429. doi: 10.1002/rse2.198



- Gilmore, M.S., Wilson, E.H., Barrett, N., Civco, D., Prisloe, S., Hurd, J.D. & Chadwick, G. (2008) Integrating multi-temporal spectral and structural information to map wetland vegetation in a lower Connecticut river tidal marsh. *Remote Sensing of Environment* 112 4048-4060. doi:10.1016/j.rse.2008.05.02
- Glenn, E.P., Huete, A.R., Nagler, P.L. & Nelson, S.G. (2008). Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: What vegetation indices can and cannot tell us about the landscape. *Sensors* 8(4) 2136–2160. <https://doi.org/10.3390/s8042136>
- Huhta, A. (2008) *Rantojen kaunistus vai kauhistus – järviruo'on (Phragmites australis) merkitys vesien laadulle*. Turun ammattikorkeakoulun puheenvuoroja 41. <https://julkaisut.turkuamk.fi/isbn9789522160393.pdf>
- Ikonen, I. & Hagelberg, E. (2007a; toim) *Reed up on reed!* Vammalan kirjapaino Oy.
- Ikonen, I. & Hagelberg, E. (2007b; toim) *Ruovikot ja merenrantaniityt – Luontoarvot ja hoitokokemuksia Etelä-Suomesta ja Virosta*. Suomen Ympäristö 37. [https://helda.helsinki.fi/bitstream/handle/10138/38394/SY37\\_2007\\_Ruovikot\\_ja\\_merenrantaniityt.pdf?sequence=1](https://helda.helsinki.fi/bitstream/handle/10138/38394/SY37_2007_Ruovikot_ja_merenrantaniityt.pdf?sequence=1)
- Ikonen, I. & Hagelberg, E. (2008) *Etelä-Suomen ruovikkostrategia. Esimerkkeinä Halikonlahti ja Turun kaupungin rannikkoalueet*. Suomen Ympäristö 9. [https://helda.helsinki.fi/bitstream/handle/10138/38347/SY9\\_2008\\_sivut\\_1-44.pdf?sequence=1](https://helda.helsinki.fi/bitstream/handle/10138/38347/SY9_2008_sivut_1-44.pdf?sequence=1)  
[https://helda.helsinki.fi/bitstream/handle/10138/38347/SY9\\_2008\\_sivut\\_45-72.pdf?sequence=2](https://helda.helsinki.fi/bitstream/handle/10138/38347/SY9_2008_sivut_45-72.pdf?sequence=2)
- Jones, H.G. & Vaughan, R.A. (2010) *Remote sensing of vegetation. Principles, techniques, and applications*. Oxford University Press, New York.
- Juvonen, S.-K. & Kurikka, T. (2016) *Suomen Ramsar -kosteikkotoimintaohjelma 2016-2020*. Ympäristöministeriön raportteja 21.

[https://julkaisut.valtioneuvosto.fi/bitstream/handle/10024/75329/YMra\\_21\\_2016.pdf?sequence=1](https://julkaisut.valtioneuvosto.fi/bitstream/handle/10024/75329/YMra_21_2016.pdf?sequence=1)

- Fotso Kamga, G.A., Bitjoka, L., Akram, T., Mengue Mbom, A., Rameez Naqvi, S. & Bouroubi, Y. (2021) Advancements in satellite image classification: methodologies, techniques, approaches, and applications. *International Journal of Remote Sensing* 42(20) 7662–7722. <https://doi.org/10.1080/01431161.2021.1954261>
- Korpinen, S., Laamanen, M., Suomela, J., Paavilainen, P., Lahtinen, T. & Ekebom, J. (toim.) (2018) *Suomen meriympäristön tila 2018*. SYKEn julkaisuja 4. Grano, Helsinki.
- Laamanen, M., Suomela, J., Ekebom, J., Korpinen, S., Paavilainen, P., Lahtinen, T., Nieminen, S. & Hernberg, A. (toim.) (2021) *Suomen merenhoitosuunnitelman toimenpideohjelma vuosille 2022-2027*. Ympäristöministeriön julkaisuja 30. <http://urn.fi/URN:ISBN:978-952-361-198-6>
- Leikkuun hyödyt (2022) ELY-keskus 17.01.2022 < <https://www.ely-keskus.fi/web/ruoko/leikkuun-hyodyt>>
- Li, W., Dou, Z., Wang, Y., Wu, G., Zhang, M., Lei, Y., Ping, Y., Wang, J., Cui, L. & Ma, W. (2019) Estimation of above-ground biomass of reed (*Phragmites communis*) based on in situ hyperspectral data in 16 Beijing Hanshiqiao wetland, China. *Wetlands Ecology and Management* 27 87–102. <https://doi.org/10.1007/s11273-018-9644-5>
- Lumbierres, M., Mendez, P.F., Bustamante, J., Soriguer, R. & Santamaria, L. (2017) Modeling biomass production in seasonal wetlands using MODIS NDVI land surface phenology. *Remote Sensing* 9 392. doi:10.3390/rs9040392
- Milke, J., Galczynska, M. & Wrobel, J. (2020) The importance of biological and ecological properties of *Phragmites australis* (Cav.) Trin. Ex Steud., in phytoremediation of aquatic ecosystems-The Review. *Water* 12 1770. <http://dx.doi.org/10.3390/w12061770>

- Myrberg, K., Kuosa, H. & Leppäranta, M. (2006) *Itämeren fysiikka, tila ja tulevaisuus*.  
Yliopistopaino: Helsinki.
- Ojaveer, H., Jaanus, A., MacKenzie, B.R., Martin, G., Olenin, S., Radziejewska, T., Telesh, I., Zettler, M.L. & Zaiko, A. (2010) Status of biodiversity in the Baltic Sea. *PLoS ONE* 5(9). doi:10.1371/journal.pone.0012467
- Onojeghuo, A.O. & Blackburn, G. (2011) Optimizing the use of hyperspectral and LiDAR data for mapping reedbed habitats. *Remote Sensing* 115 2025–2034.  
<http://dx.doi.org/10.1016/j.rse.2011.04.004>
- Onojeghuo, A.O. & Blackburn, G. (2016) Exploiting high resolution multi-seasonal textural measures and spectral information for reedbed mapping. *Environments* 3(5).  
doi:10.3390/environments3010005
- Pitkänen, T. (2006) *Missä ruokoa kasvaa? – Järviruokoalueiden satelliittikartoitus Etelä-Suomen ja Viron Väinämeren rannoilla*. Turun ammattikorkeakoulun puheenvuoroja 29. <https://julkaisut.turkuamk.fi/isbn9525596664.pdf>
- Resolutions (s.a) European Space Agency. <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions>>
- Rupasinghe, P.A. & Chow-Fraser, P. (2019) Identification of most spectrally distinguishable phenological stage of invasive *Phragmites australis* in Lake Erie wetlands (Canada) for accurate mapping using multispectral satellite imagery. *Wetlands Ecology and Management* 27 513-538. <https://doi.org/10.1007/s11273-019-09675-2>
- Rupasinghe, P.A. & Chow-Fraser, P. (2021) Mapping *Phragmites* cover using WorldView 2/3 and Sentinel 2 images at Lake Erie wetlands, Canada. *Biological Invasions* 23 1231–1247. <https://doi.org/10.1007/s10530-020-02432-0>
- SNAP (s.a.) European Space Agency. < <http://step.esa.int/main/toolboxes/snap/>>

- Stratoulas, D., Baltzer, H., Sykioti, O., Zlinsky, A. & Toth, V.R. (2015) Evaluating Sentinel-2 for lakeshore habitat mapping based on airborne hyperspectral data. *Sensors* 15 22956–22969. doi:10.3390/s150922956
- Thamaga, K.H., Duke, T. & Shoko, C. (2021) Advances in satellite remote sensing of the wetland ecosystems in Sub-Saharan Africa. *Geocarto International*.  
<https://doi.org/10.1080/10106049.2021.1926552>
- Tornikoski, J. & Simi-Virahsawmy, J. (2020) *Järviruo 'on biomassan arviointi ilmakuvien perusteella*. Turun ammattikorkeakoulun ruokopajan raportti. 31 s.
- Tuominen, J. & Lipping, T. (2016) Spectral characteristics of common reed beds: studies on spatial and temporal variability. *Remote Sensing* 8(181). doi:10.3390/rs8030181
- Tähtinen, J., Laakkonen, E. & Broberg, M. (2020) *Tilastollisen aineiston käsittelyn ja tulkinnan perusteita*. Turun yliopiston kasvatustieteiden tiedekunnan julkaisusarja C, oppimateriaalit 22. <https://urn.fi/URN:ISBN:978-951-29-8091-8>
- Wilson, K.L., Wong, M.C. & Devred, E. (2022) Comparing Sentinel-2 and WorldView-3 Imagery for Coastal Bottom Habitat Mapping in Atlantic Canada. *Remote Sensing* 14 1254. <https://doi.org/10.3390/rs14051254>
- Zhao, Y., Mao, D., Zhang, D., Wang, Z., Du, D., Yan, H., Qiu, Z., Feng, K., Wang, F. & Jia, M. (2022) Mapping *Phragmites australis* aboveground biomass in the Momoge wetland Ramsar site based on Sentinel-1/2 images. *Remote Sensing* 14 649.  
<https://doi.org/10.3390/rs14030694>

## Liitteet

## Liite 1 Spearmanin korrelaatiokertoimet, Sentinel 2 -satelliittikuva 02.10.2020

		Korrelaatiot															
		B2	B3	B4	B5	B6	B7	B8	B11	B12	ndvi	dvi	msavi	savi	ndwi	biomass	
Spearman's rho	B2	Korrelaatiokerroin	1,000	,782**	,720**	,530**	,459**	,449**	,525**	,457**	,477**	,062**	,355**	,321**	,297**	,237**	,016
		Sig. (2-suuntainen)	.	,000	,000	,000	,000	,000	,000	,000	,000	,001	,000	,000	,000	,000	,890
		N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132
B3	Korrelaatiokerroin	,782**	1,000	,749**	,570**	,519**	,501**	,665**	,396**	,415**	,227**	,520**	,488**	,464**	,369**	,080	
	Sig. (2-suuntainen)	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,494	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
B4	Korrelaatiokerroin	,720**	,749**	1,000	,728**	,597**	,600**	,756**	,706**	,724**	,186**	,548**	,507**	,476**	,398**	,377**	
	Sig. (2-suuntainen)	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,001	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
B5	Korrelaatiokerroin	,530**	,570**	,728**	1,000	,828**	,819**	,664**	,858**	,872**	,278**	,534**	,506**	,485**	,052**	,074	
	Sig. (2-suuntainen)	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,000	,004	,531	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
B6	Korrelaatiokerroin	,459**	,519**	,597**	,828**	1,000	,972**	,679**	,750**	,722**	,451**	,627**	,611**	,598**	-,047**	-,029	
	Sig. (2-suuntainen)	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,009	,802	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
B7	Korrelaatiokerroin	,449**	,501**	,600**	,819**	,972**	1,000	,682**	,771**	,740**	,452**	,628**	,611**	,599**	-,065**	-,009	
	Sig. (2-suuntainen)	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,940	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
B8	Korrelaatiokerroin	,525**	,665**	,756**	,664**	,679**	,682**	1,000	,666**	,649**	,713**	,947**	,926**	,910**	,617**	,353**	
	Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,002	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
B11	Korrelaatiokerroin	,457**	,396**	,706**	,858**	,750**	,771**	,666**	1,000	,989**	,321**	,550**	,525**	,506**	,114**	,079	
	Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,500	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
B12	Korrelaatiokerroin	,477**	,415**	,724**	,872**	,722**	,740**	,649**	,989**	1,000	,277**	,519**	,492**	,472**	,118**	,085	
	Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,467	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
ndvi	Korrelaatiokerroin	,062**	,227**	,186**	,278**	,451**	,452**	,713**	,321**	,277**	1,000	,888**	,912**	,928**	,525**	,230**	
	Sig. (2-suuntainen)	,001	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,047	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
dvi	Korrelaatiokerroin	,355**	,520**	,548**	,534**	,627**	,628**	,947**	,550**	,519**	,888**	1,000	,998**	,995**	,615**	,320**	
	Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,005	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
msavi	Korrelaatiokerroin	,321**	,488**	,507**	,506**	,611**	,611**	,926**	,525**	,492**	,912**	,998**	1,000	,999**	,610**	,313**	
	Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,006	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
savi	Korrelaatiokerroin	,297**	,464**	,476**	,485**	,598**	,599**	,910**	,506**	,472**	,926**	,995**	,999**	1,000	,604**	,306**	
	Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,008	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
ndwi	Korrelaatiokerroin	,237**	,369**	,398**	,052**	-,047**	-,065**	,617**	,114**	,118**	,525**	,615**	,610**	,604**	1,000	,291**	
	Sig. (2-suuntainen)	,000	,000	,000	,004	,009	,000	,000	,000	,000	,000	,000	,000	,000	.	,011	
	N	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	3132	75
biomass	Korrelaatiokerroin	,016	,080	,377**	,074	-,029	-,009	,353**	,079	,085	,230**	,320**	,313**	,306**	,291**	1,000	
	Sig. (2-suuntainen)	,890	,494	,001	,531	,802	,940	,002	,500	,467	,047	,005	,006	,008	,011	.	
	N	75	75	75	75	75	75	75	75	75	75	75	75	75	75	75	75

\*\* Korrelaatio on merkitsevä 0.01 tasolla (2-suuntainen).

\* Korrelaatio on merkitsevä 0.05 tasolla (2-suuntainen).

## Liite 2 Spearmanin korrelaatiokertoimet, Sentinel 2 -satelliittikuva 30.08.2022

		Korrelaatiot															
		B2	B3	B4	B5	B6	B7	B8	B11	B12	ndvi	dvi	msavi	ndwi	savi	biomass	
Spearman's rho	B2	Korrelaatiokerroin	1,000	,859**	,978**	,787**	,476**	,445**	,441**	,709**	,791**	,043	,357**	,315**	,067**	,296**	,579**
		Sig. (2-suuntainen)	.	,000	,000	,000	,000	,000	,000	,000	,000	,012	,000	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B3	Korrelaatiokerroin	,859**	1,000	,804**	,872**	,631**	,593**	,601**	,761**	,769**	,199**	,522**	,480**	,117**	,462**	,579**
		Sig. (2-suuntainen)	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B4	Korrelaatiokerroin	,878**	,804**	1,000	,789**	,327**	,295**	,274**	,657**	,815**	-,149**	,178**	,131**	-,012	,111**	,581**
		Sig. (2-suuntainen)	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,000	,466	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B5	Korrelaatiokerroin	,787**	,872**	,789**	1,000	,650**	,608**	,549**	,851**	,871**	,175**	,475**	,436**	-,027	,419**	,579**
		Sig. (2-suuntainen)	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,113	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B6	Korrelaatiokerroin	,476**	,631**	,327**	,650**	1,000	,987**	,928**	,770**	,538**	,734**	,912**	,899**	,158**	,892**	,577**
		Sig. (2-suuntainen)	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B7	Korrelaatiokerroin	,445**	,593**	,295**	,608**	,987**	1,000	,940**	,744**	,499**	,764**	,929**	,918**	,205**	,912**	,578**
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B8	Korrelaatiokerroin	,441**	,601**	,274**	,549**	,928**	,940**	1,000	,687**	,446**	,815**	,990**	,979**	,434**	,973**	,577**
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B11	Korrelaatiokerroin	,709**	,761**	,657**	,851**	,770**	,744**	,687**	1,000	,905**	,353**	,628**	,595**	,070**	,580**	,578**
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	B12	Korrelaatiokerroin	,791**	,769**	,815**	,871**	,538**	,499**	,446**	,905**	1,000	,090**	,372**	,335**	-,027	,318**	,577**
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,117	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	ndvi	Korrelaatiokerroin	,043	,199**	-,149**	,175**	,734**	,764**	,815**	,353**	,090**	1,000	,879**	,906**	,438**	,917**	,570**
		Sig. (2-suuntainen)	,012	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	dvi	Korrelaatiokerroin	,357**	,522**	,178**	,475**	,912**	,929**	,990**	,628**	,372**	,879**	1,000	,998**	,449**	,995**	,576**
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	msavi	Korrelaatiokerroin	,315**	,480**	,131**	,436**	,899**	,918**	,979**	,595**	,335**	,906**	,998**	1,000	,453**	1,000**	,576**
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	.	,000	,000	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	ndwi	Korrelaatiokerroin	,067**	,117**	-,012	-,027	,158**	,205**	,434**	,070**	-,027	,438**	,449**	,453**	1,000	,454**	,146
		Sig. (2-suuntainen)	,000	,000	,466	,113	,000	,000	,000	,000	,117	,000	,000	,000	.	,000	,256
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	savi	Korrelaatiokerroin	,296**	,462**	,111**	,419**	,892**	,912**	,973**	,580**	,318**	,917**	,995**	1,000**	,454**	1,000	,576**
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	.	,000
		N	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	3482	62
	biomass	Korrelaatiokerroin	,579**	,579**	,581**	,579**	,577**	,578**	,577**	,578**	,577**	,570**	,576**	,576**	,146	,576**	1,000
		Sig. (2-suuntainen)	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,000	,256	,000	.
		N	62	62	62	62	62	62	62	62	62	62	62	62	62	62	62

\*\* Korrelaatio on merkitsevä 0.01 tasolla (2-suuntainen).

\* Korrelaatio on merkitsevä 0.05 tasolla (2-suuntainen).