

Pohjoisboreaalisten soiden kasvillisuuden ja maanpeitteen tarkan mittakaavan kaukokartoitus

Ultra-high resolution remote sensing of northern boreal peatland vegetation and land cover

Aleksi Räsänen & Tarmo Virtanen

Aleksi Räsänen, Ekosysteemit ja ympäristö -tutkimusohjelma, Helsingin yliopisto, aleksi.rasanen@helsinki.fi; Tarmo Virtanen, Ekosysteemit ja ympäristö -tutkimusohjelma, Helsingin yliopisto, tarmo.virtanen@helsinki.fi

Johdanto

Pohjoisboreaalisilla suoalueilla maanpeitteen ja kasvillisuuden vaihtelu on spatiaalisesti pieni-piirteistä. Vastaavasti ekosysteemin prosessit ja biogeokemialliset kierrot, kuten esimerkiksi hiilen kierto, ovat sidoksissa kasvillisuuteen ja maanpeitteeseen. Näiden syiden takia suon toiminnan mallintamisessa tarvitaan tarkan mittakaavan suokasvillisuuskarttoja.

Miehittämättömät lennokit eli dronet ovat tuoneet uusia mahdollisuuksia hyvin tarkan mittakaavan automatisoituihin kasvillisuus-kartoituksiin. On kuitenkin tehty verraten vähän tutkimusta, millaisilla aineistoyhdistelmillä ja lähestymistavoilla kasvillisuuskarttoituksia olisi parasta tehdä. Tutkimuksemme jakaantui neljään osatutkimukseen, joilla oli omat tutkimuskysymyksensä:

1. Mitkä ovat seuraavien menetelmien edut suokasvillisuuden kartoittamisessa: (i) ennalta määrättyjen maanpeitetyyppien luokittelu ja (ii) kasvillisuusruutuaineistojen perusteella muodostetut kasviyhteisöt? (Räsänen ym. 2019)
2. Miten maanpeiteluokittelun ennustetarkkuus muuttuu, kun lähtöaineistojen mittakaavaa

vaihdetaan tai kun eri aineistoja otetaan mukaan tai pois luokittelusta? (Räsänen & Virtanen 2019)

3. Miten hyvin eri kaukokartoitusmenetelmät toimivat eri suoalueilla? (Räsänen ym. 2020a)
4. Miten paljon hyperspektriset lennokkaaineistot parantavat ennustetarkkuutta kasvillisuuden kaukokartoituksessa? (Räsänen ym. 2020b)

Aineistot ja menetelmät

Kartoitimme kasvillisuutta ja maanpeitettä Inarin Kaamasessa Pässirovalla (69.140° P, 27.270° I; osatutkimukset 1–3), Sodankylän Halssiaavalla (67.368° P, 26.654° I; osatutkimukset 3–4) ja Pallaksen Lompolojäнкällä (67.997° P, 24.210° I; osatutkimus 3). Kaikki 20–40 ha tutkimusalueet sijaitsevat pohjoisboreaalisella kasvillisuusvyöhykkeellä, mutta soiden välillä on suuria eroja maiseman ja kasvillisuuden rakenteessa: Kaamasessa vuorottelevat märät rimmet ja vajaan metrin korkuiset jänteet, Halssiaavalla jännerimpi-rakenteen korkeusvaihtelut ja vaihettumat ovat hienovaraisempia, kun taas Lompolojäнкä on tasainen ja märkä sarasuo, jonka keskellä virtaa pieni puro (Kuva 1).



Kuva 1. Valokuvat (ylhäältä alas) Kaamasen, Halssiaavan ja Lompolojänkkän tutkimusalueilta. (valokuvat: Tarmo Virtanen)

Figure 1. Photographs (from top to bottom) from Kaamasen, Halssiaapa and Lompolojänkkä mire study areas. (Photos. Tarmo Virtanen)

Pääasiallisena maastoaineistona käytimme joka suolta vuonna 2018 kerättyä kasvillisuusruutuaineistoa. 140–200:sta 50×50 cm ruudusta tunnistettiin jokainen sammal- ja putkilokasvilaji ja niiden peittävyyttä arvioitiin silmämääräisesti. Jokaisen ruudun sijainti tallennettiin tarkkuus-GPS-laitteen avulla ± 5 cm sijaintitarkkuudella. Käytimme myös aiemmin kerättyjä maastoaineistoja.

Kaukokartoitusaineistot koostuivat lennökkikuvista, ilmakuvista, laserkeilausaineistoista ja tarkan mittakaavan satelliittikuvista (Taulukko 1). Eri aineistoista laskimme erityyppisiä piirteitä, jotka kertoivat kasvillisuuden ja maanpeitteen spektristä ominaisuuksista, tekstuurista eli spektristen omi-

naisuuksien spatiaalisesta vaihtelusta, topografiasta ja kasvillisuuden korkeudesta. Lisäksi aineistot ja niiltä laskettavat piirteet olivat eri mittakaavatasoilla (pikselikoko 2 cm–3 m). Käytimme useaa karkeimman mittakaavan satelliittikuvaa, joten pystyimme myös tarkastelemaan kasvillisuuden kehitystä kasvukauden yli. Osatutkimuksessa 4 käytimme lisäksi hyperspektristä lennökkikuvaa, joka sisälsi 28 kapeaa värikanavaa.

Kaukokartoitusanalyysi koostui kahdesta vaiheesta. Ensiksi kuvioimme yhden kuva-aineiston, yleensä lennökkikuvan, homogeenisiin kasvillisuuslaikkuihin käyttämällä automaattisia segmentointimenetelmiä. Tämän jälkeen laskimme jokaiselle kuviolle ja jokaiselle kasvillisuusruudulle piirteitä kaukokartoitusaineistoista (Taulukko 1) ja ennustimme piirteiden avulla kuviolle erityyppisiä kasvillisuustietoja käyttämällä pääosin ”random forest” -menetelmää.

Osatutkimuksessa 1 luokittelimme Kaamasen maanpeitteen kymmeneen eri luokkaan ja ennustimme viiden eri kasviyhteisön esiintymistä regressiomenetelmän avulla. Maanpeiteluokat muodostimme oman maastossa kerätyn näkemyksemme avulla, kun taas kasviyhteisöt muodostimme kasviruutuaineistojen avulla käyttämällä automaattisia oordinaatio- ja klusterointimenetelmiä.

Osatutkimuksessa 2 vertailimme 78:aa kymmenluokkaista maanpeiteluokittelua Kaamasessa. Luokittelut erosivat toisistaan kolmella eri tavalla. Ensiksi kokeilimme kuvioita neljää eri kaukokartoituskuva: lennökkikuvaa (5 cm pikselikoko), ilmakuva (50 cm), WorldView-2-satelliittikuvaa (2 m) ja PlanetScope-satelliittikuvaa (3 m). Toiseksi kokeilimme neljää eri kuvion keskikokoa segmentoinnissa: 2,5; 5; 10 ja 20 m². Kolmanneksi kokeilimme kuutta eri aineistoyhdistelmää luokitteluisa: (1) piirteet yhdestä kuva-aineistosta, (2) 1 ja tekstuuripiirteet, (3) 1 ja topografiset piirteet ja kasvillisuuden korkeus, (4) piirteet useasta eri kuvasta ilman tekstuuria, (5) 4 ja topografia ja kasvillisuuden korkeus (6) 5 ja tekstuuripiirteet.

Osatutkimuksessa 3 ennustimme kaikille kolmelle suolle seuraavia kasvillisuusruutuaineiston avulla laskemiamme kasvillisuuspiirteitä: toiminnalliset kasviryhmät (ainavihannat varvut, kausivihannat varvut, pajupensaat, saramaiset kasvit, muut ruohovartiset putkilokasvit, rahkasammalet, metsäsammalet, märät rimpisammalet), auto-

Taulukko 1. Kuvaus kaukokartoitusaineistoista.

Table 1. Description of remote sensing datasets.

Aineisto Data	Lähde Source	Spatiaalinen resoluutio Spatial resolution	Rasteritasot ja piirteet Raster layers and features
Lennoikkikuvat Drone images	Ilmatieteen laitos, Itä-Suomen yliopisto Finnish Meteorological Institute, University of Eastern Finland	0.02–0.05 m 0.02–0.05 m	3 värikanavaa, tekstuuri 3 spectral bands, texture
Korkeusmalli lennoikkikuvien avulla Drone digital elevation model	Ilmatieteen laitos, Itä-Suomen yliopisto Finnish Meteorological Institute, University of Eastern Finland	0.08–0.13 m 0.08–0.13 m	Eri topografisia piirteitä, kasvillisuuden korkeusmalli Different topographic features, vegetation height model
Ilmakuva Aerial image	Maanmittauslaitos National Land Survey of Finland	0.5 m 0.5 m	4 värikanavaa, tekstuuri** 4 spectral bands, texture**
Laserkeilausaineisto Lidar data	Maanmittauslaitos National Land Survey of Finland	0.5 pistettä m ⁻² (pistepilvi); 2 m (rasteritasot) 0.5 points m ⁻² (point cloud); 2 m (raster layers)	Eri topografisia piirteitä, kasvillisuuden korkeusmalli Different topographic features, vegetation height model
WorldView-2 satelliittikuva* WorldView-2 satellite image*	Digital Globe Inc. Digital Globe Inc.	2 m 2 m	8 värikanavaa, 3 spektri- indeksiä, tekstuuri** 8 spectral bands, 3 spectral indices, texture**
PlanetScope- satelliittikuvat PlanetScope satellite images	Planet Labs Inc. Planet Labs Inc.	3 m 3 m	Useampi kuva yhdeltä kesältä, 4 värikanavaa, 3 spektri- indeksiä, tekstuuri** Multiple images from one summer, 4 spectral bands, 3 spectral indices, texture**
Hyperspektrin lennoikkikuva*** Hyperspectral drone image***	Ilmatieteen laitos Finnish Meteorological Institute	0.07 m 0.07 m	28 värikanavaa, 80 spektri- indeksiä 28 spectral bands, 80 spectral indices

*Osatutkimukset 1 ja 2 **Osatutkimus 2 ***Osatutkimus 4

*Sub-studies 1 and 2 **Sub-study 2 ***Sub-study 4

maattisesti muodostetut neljä kasvillisuuden vaihtumista kertovaa ordinaatioakselia, ja automaattisesti muodostetut kasvivyhteisöt (2–5 kappaletta riippuen tutkimusalueesta).

Osatutkimuksessa 4 muodostimme Halssi-aavalle lehtipinta-ala- ja biomassakartat sekä eri toiminnallisille kasviryhmille että kokonais-lehtipinta-alalle ja biomassalle. Lehtipinta-alan ja biomassan mittaussuunnitelmamme 40:stä vuonna 2014 nypitystä kasvillisuusruudusta ja muodostimme nypitysten näytteiden avulla lehtipinta-alan ja

biomassan regressioyhtälöt toiminnallisille kasviryhmille. Tämän jälkeen ennustimme biomassan ja lehtipinta-alan vuonna 2018 inventoiduille kasvillisuusruuduille, ja edelleen teimme kartat kaukokartoitusaineistojen avulla. Kokeilimme lehtipinta-alan ja biomassan ennustamisessa kolmea eri kaukokartoitusaineistoyhdistelmää: (1) aineistona ainoastaan hyperspektrininen lennoikkikuva, (2) aineistona kaikki muut aineistot paitsi hyperspektrikuva ja (3) kaikki kaukokartoitusaineistot.

Tulokset

Osatutkimuksen 1 mukaan ennalta määrättyjen ja maanpeitetyyppien luokittelulla oli korkeampi luokittelutarkkuus (kokonaisluokittelutarkkuus 72%) kuin kasviyhteisöregressioilla (selitysasteet eri kasviyhteisöille 27–67%). Lisäksi maanpeitetyyppikarttaa on helpompi tulkita ja käyttää kuin kasviyhteisökarttoja, mutta kasviyhteisökartat kuvaavat realistisemmin pienialaisia kasvillisuusvaihteluita ja havainnollistavat, että muutokset maanpeitetyyppien välillä eivät ole tarkkarajaisia (kuva 2). Siten maanpeitetyyppiluokittelu ja kasviyhteisöregressiot täydentävät toisiaan.

Osatutkimuksen 2 mukaan maanpeitteen luokittelutarkkuudet nousivat huomattavasti, kun luokitteluun otettiin mukaan muita aineistoja kuin pelkkä yksi kuva: usean kuva-aineiston lisääminen luokitteluun lisäsi tarkkuutta 8.2–20.4 %-yksikköä, topografiset piirteet ja kasvillisuuden korkeusaineisto lisäsivät tarkkuutta 8.0–19.9 %-yksikköä ja useampi kuva, topografiset piirteet ja kasvillisuuden korkeus lisäsivät tarkkuutta 10.6–25.0 %-yksikköä. Tekstuuri lisäsi luokittelutarkkuutta yhden kuvan luokitteluissa 0.4–12.1 %-yksikköä mutta tekstuurin vaikutus oli vähäinen silloin, kun mukana oli muita aineistoja (0.4 %-yksikön lisäys – 2.1 %-yksikön vähennys luokittelutarkkuudessa). Niissä monen aineiston luokitteluissa, joissa ilma- tai lennokkikuvat olivat mukana, luokittelutarkkuudet olivat 4.6–12.7 %-yksikköä korkeampia kuin niissä luokitteluissa, joissa ne eivät olleet mukana (kuva 3). Kuviointikoon vaikutus luokittelutarkkuuteen oli kohtalaisen pieni (2.5–7.3 %-yksikköä).

Osatutkimuksen 3 mukaan soiden ja kasvillisuuspiirteiden välillä oli merkittäviä eroja luokittelu- ja ennustetarkkuuksissa. Parhaisiin ennustetarkkuuksiin päästiin Kaamasessa, kun taas ennustetarkkuudet olivat heikoimmat Lompolojänkällä. Toiminnallisten kasviryhmien regressioissa selitysasteet vaihtelivat huomattavasti (–3–69%). Ensimmäinen ordinaatioakseli kuvasi kasvillisuuden vaihtelua suon märkyymen mukaan (kuva 4) ja pystyttiin ennustamaan hyvin jokaisella tutkimusalueella (selitysaste 64–82%), mutta muille ordinaatioakseleille ennustetarkkuus oli

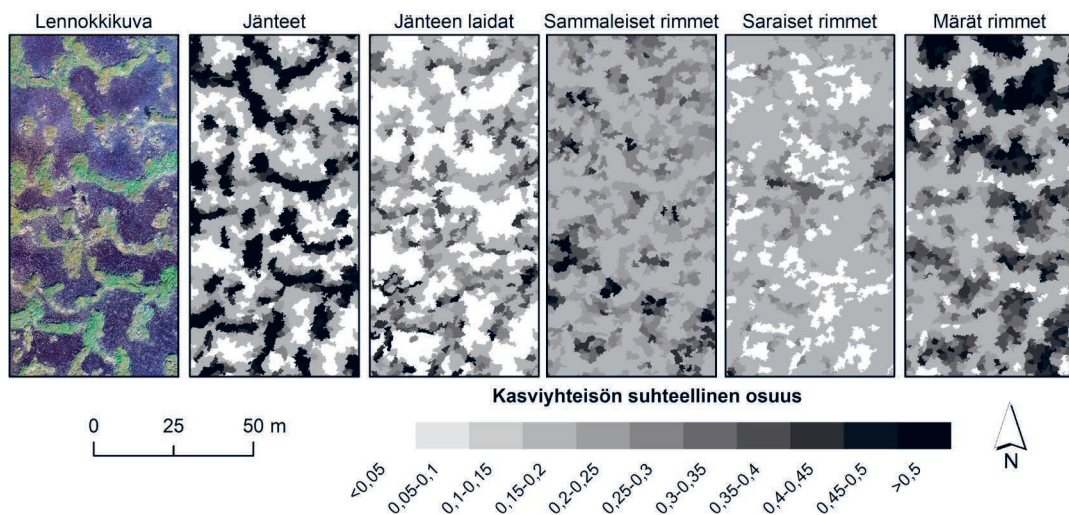
heikompi. Kasviyhteisöregressiot toimivat hyvin Kaamasessa mutta heikommin Halssiaavalla ja Lompolojänkällä (selitysasteet 16–82%).

Osatutkimuksen 4 mukaan ennustetarkkuudet olivat kohtalaisen hyvät kenttäkerroksen kasvillisuuden kokonaislehtipinta-alalle (67%) ja -biomassalle (selitysaste 50%) (kuva 5). Sen sijaan yksittäisillä toiminnallisilla ryhmillä selitysasteet vaihtelivat huonon ja hyvän välillä (0–62%). Hyperspektriset lennokkiaineistot lisäsivät ennustetarkkuutta useimmissa malleissa. Vaikutus oli yleensä tosin melko pieni: esimerkiksi kokonaislehtipinta-alalla 5 %-yksikköä ja kokonaisbiomassalla 1 %-yksikkö. Kausivihantien varpujen regressioissa hyperspektriaineistot jopa vähensivät selitystasetta. Kuitenkin myös regressiot, joissa oli mukana pelkät hyperspektriaineistot, toimivat useimmissa malleissa melko hyvin: kokonaislehtipinta-alalla selitysaste oli 7 %-yksikköä ja kokonaisbiomassalla 6 %-yksikköä pienempi kuin malleissa, joissa oli mukana kaikki aineistot.

Johtopäätökset

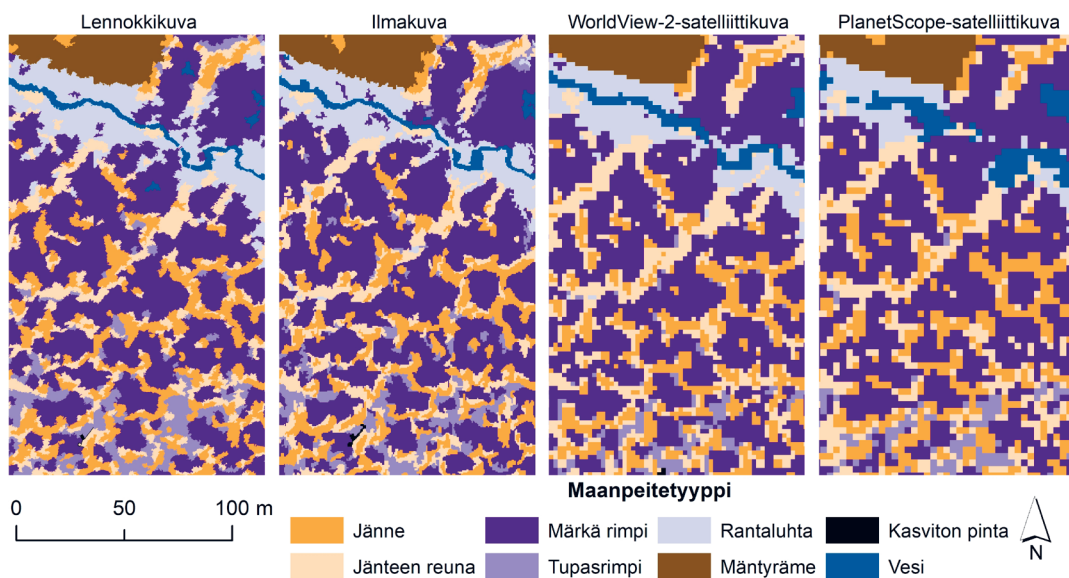
Tutkimuksemme osoittaa, että suokasvillisuudesta voidaan tehdä hyvinkin tarkkoja kasvillisuuskarttoja maastotukiaineiston ja lennokkiaineistojen avulla. Karttojen teossa tarvitaan kuitenkin myös muita aineistoja – etenkin kuva-aineistojen yhdistäminen topografiasta ja kasvillisuuden korkeudesta kertovien aineistojen kanssa tuo hyvän lopputuloksen. Parhaan ennustetarkkuuden saamiseksi tarvitaan joko tarkkan mittakaavan lennokki- tai ilmapokuva-aineistoja, mutta erittäin tarkkojen hyperspektristen lennokkiaineistojen lisäarvo on kohtalaisen vähäinen. Tutkimuksemme mukaan soiden välillä on suuria eroja ennustetarkkuudessa, erilaiset lähestymistavat toimivat erityyppisillä soilla ja erityyppiset kartat täydentävät toisiaan. Tämän takia useita eri aineistoja ja lähestymistapoja kannattaa kokeilla ja yhdistellä tarpeen mukaan.

Kiitokset: Tutkimusta on rahoittanut Suomen Akatemia (hankkeet 296423, 308513).



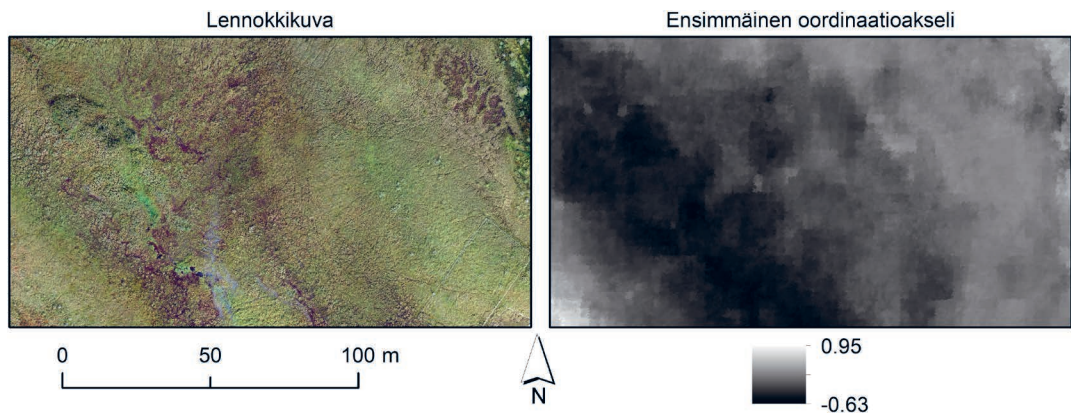
Kuva 2. Lennokkikuva ja kasvyhteisökartat Kaamasen tutkimusalueelle (osatutkimus 1). Kasvyhteisöt on nimetty pääasiallisen kasvupaikan mukaan. Jokaisessa kartan kohdassa jokaiselle kasvyhteisölle on ennustettu suhteellinen osuus välillä 0–1.

Figure 2. Drone image and plant community maps for Kaamanen study area. Each map represents membership degree for one plant community in each map location.




Kuva 3. Maanpeiteluokittelu Kaamasen tutkimusalueelle (osatutkimus 2). Luokittelujen pohjana on lennokki-, ilma- tai satelliittikuvan kuviointi. Kuvioidun aineiston spatiaalinen resoluutio ja luokittelutarkkuus heikkenevät kuvassa vasemmalta oikealle.

Figure 3. Land cover classification for Kaamanen study area based on segmentation of drone image, aerial image, WorldView-2 satellite image and PlanetScope satellite image, respectively. The spatial resolution of segmented image and classification accuracy decreases from left to right.



Kuva 4. Lennokkikuva ja ensimmäinen ordinaatioakseli Lompolojätkän tutkimusalueella (osatutkimus 3). Ordinaatioakseli kuvaa kasvillisuuden vaihtelua märkyuden mukaan siten, että isot arvot kuvaavat kuivan paikan kasvillisuutta ja pienet arvot mären.

Figure 4. Drone image and first ordination axis for Lompolojätkä study area. First ordination axis describes wetness gradient so that large values indicate vegetation on wetter areas and small values indicate vegetation on drier areas.



Kuva 5. Lennokkikuva sekä kenttäkerroksen lehtipinta-ala- ja biomassakartat Halsiaaavan tutkimusalueella (osatutkimus 4).

Figure 5. Drone image and maps of leaf-area index and biomass for Halsiaaapa study area.

Kirjallisuus

- Räsänen, A., & Virtanen, T. 2019. Data and resolution requirements in mapping vegetation in spatially heterogeneous landscapes. *Remote Sensing of Environment* 230: 111207. <https://doi.org/10.1016/j.rse.2019.05.026>
- Räsänen, A., Juutinen, S., Tuittila, E. S., Aurela, M. & Virtanen, T. 2019. Comparing ultra-high spatial resolution remote-sensing methods in mapping peatland vegetation. *Journal of Vegetation Science* 30(5): 1016–1026. <https://doi.org/10.1111/jvs.12769>
- Räsänen, A., Aurela, M., Juutinen, S., Kumpula, T., Lohila, A., Penttilä, T. & Virtanen, T. 2020a. Detecting northern peatland vegetation patterns at ultra-high spatial resolution. *Remote Sensing in Ecology and Conservation* 6(4): 457–471. <https://doi.org/10.1002/rse2.140>
- Räsänen, A., Juutinen, S., Kalacska, M., Aurela, M., Heikkinen, P., Mäenpää, K., Rimali, A. & Virtanen, T. 2020b. Peatland leaf-area index and biomass estimation with ultra-high resolution remote sensing. *GIScience & Remote Sensing* 57(7): 943–964. <https://doi.org/10.1080/15481603.2020.1829377>

Summary: Ultra-high resolution remote sensing of northern boreal peatland vegetation and land cover

Northern boreal peatlands have fine-scale spatial heterogeneity in land cover and vegetation patterns. We produced ultra-high spatial resolution vegetation and land cover maps in three different peatland sites in Finnish Lapland, using drone data, aerial images and lidar data, as well as satellite imagery. Our study was divided into four sub-studies. First, we compared two different vegetation mapping approaches in Kaamanen mire: floristically defined plant communities and pre-defined land cover types. We found out that land cover type mapping has higher classification accuracy but plant communities show the fuzzy pattern of peatland vegetation more realistically. Second, we tested the data and resolution requirements in land cover mapping. According to the results, multiple different datasets at different scales are needed, including spectral and topographic features, and in order to achieve the highest accuracy, ≤ 0.5 m spatial resolution data should be used. Third, we evaluated how these mires (Kaamanen, Lompolojänkämä, Halssiaapa) differ structurally and vegetationally, and showed that there are notable differences between mires in how well vegetation patterns can be detected, what vegetation properties should be mapped and what the optimal remote sensing datasets are. Fourth, we assessed the relative benefit of hyperspectral drone data in detecting biomass and leaf-area index patterns in Halssiaapa mire. Hyperspectral data boosted somewhat the accuracy of the different models. Overall, accurate vegetation and land cover maps can be produced with drone and other remote sensing data, and different datasets and approaches should be tested and combined to find out the suitable methods at different study sites.