

LOPPURAPORTTI

HYPERSPEKTRIKAMERATEKNOLOGIAN HYÖDYNTÄMINEN SÄHKÖVERKKOJEN VIANPAIKANNUKSESSA JA KUNNONHALLINASSA

Versio / pvm	Tarkastaja	Hyväksyjä	Huomautukset / Muutokset
8.1.2022	Ohjausryhmä	Ohjausryhmä	

Sisällys

1	Johdanto.....	4
2	Perusta tutkimukselle.....	4
3	Tutkimuksen toteuttaminen.....	6
3.1	Tavoitteet.....	6
3.2	Työpaketit.....	7
3.3	Tutkimusorganisaatio.....	8
3.4	Tutkimusaikataulu.....	10
4	Aikaisempi tutkimus.....	10
5	Metodologia.....	12
6	Hyödyntämismahdollisuuksien kartoittaminen.....	12
6.1	Sähköverkkojen tarkastustoiminnan yleiskuvaus.....	12
6.2	Keskeiset tarkistuskohteet lentotoiminnassa.....	13
6.3	Hyperspektrikameran mahdollisuudet tarkastuskohteittain.....	15
6.4	Tutkimukseen valitut havaintotyypit.....	17
7	Kaukokartoituksen rajoitteet ja ominaisuudet.....	18
7.1	Sääolosuhteiden vaikutus lentolaitteisiin.....	18
7.2	Sääolosuhteiden vaikutus sensoreihin.....	19
8	Hyperspektrimenetelmät.....	23
8.1	Laitteistot.....	23
8.2	Esiprosessointimenetelmät.....	25
8.3	Kaukokartoitussignaalit.....	26
9	Aineiston keruu ja jatkokäsittely.....	27
9.1	Puupylväiden kunto.....	29
9.2	Jakeluverkon erottimen päävirtatie.....	39
9.3	Muuntajakoneen värimuutoksen luokittelu.....	40
9.4	Eristimien vauriot, hiushalkeamat ja pinnassa oleva kasvusto.....	43
9.5	Säievika.....	45
9.6	Kaapelipääte.....	46
9.7	PJ-ylijännitesuoja.....	48
9.8	Puulajien tunnistaminen.....	49
10	Tekoälyn hyödyntäminen aineiston jatkokäsittelyssä.....	49
11	Yhteenveto.....	51
11.1	Muuntajakoneen värimuutoksen luokittelu.....	51
11.2	Pylväiden kuntotutkimus.....	51
	Lähteet.....	53

LIITE 1. Laboratorioon toimitettujen pylväsnäytteiden kuvaukset (PylväätNäytteidenKuvaukset.xlsx)

LIITE 2. Spektrikirjasto (Spektrikirjasto.xlsx)

LIITE 3. Tutkimuksessa kehitetty Python-scripti (Rikola_AlignRadianceBSQ.py)

Lyhenneluettelo

BVLOS	Dronen lennättäminen näköyhteyden ulkopuolella (Beyond Visual Line of Sight)
CCA	Kupari-kromi-arseeni (kylläste) (Copper-Chrome-Arsenate)
CCB	Kupari-kromi-boori (kylläste) (Copper-Chrome-Boron)
CNN	Konvoluutioneuroverkot (Convolutional Neural Network)
LiDAR	Valotutka (Light Detection and Ranging)
LWIR	Pitkäaaltoinen infrapuna (Long Wave Infrared)
MWIR	Keskiaaltoinen infrapuna (Medium Wave Infrared)
NIR	Lähi-infrapuna (Near Infrared)
PAS	Päällystetty avojohdin
PEX	Ristisilloitettu polyeteeni
RGB	Punainen, vihreä ja sininen (Red Green Blue)
SWIR	Lyhytaaltoinen infrapuna (Short Wave Infrared)
UAV	Miehittämätön ilma-alus (Unmanned Aerial Vehicle)
VIS	Näkyvän valon spektri (VISible spectra)
VLOS	Dronen lennättäminen näköyhteydessä (Visual Line Of Sight)
VNIR	Näkyvä lähi-infrapuna (Visible Near Infrared)

1 Johdanto

Teknologinen kehitys sensoriteknikassa ja miehittämättömissä ilma-aluksissa on mennyt eteenpäin nopealla vauhdilla. Nykyaikaiset lennokit ja dronet pystyvät suorittamaan ennalta määritettyjä lentotehtäviä lähes täysin autonomisesti ilman ihmisen aktiivista ohjausta. Tämä on saavutettu tarkan satelliittipaikannuksen, kiihtyvyyssantureiden sekä erilaisten tutkien sekä nopeiden ja laadukkaiden telemetriayhteyksien avulla. Samaan aikaan myös dronejen toiminta-ajat ja suorituskyky ovat kasvaneet merkittävästi, mm. uudenlaisen hybriditekniikan ansiosta.

Sensoritekniikan puolella on tapahtunut merkittävää kehitystä. Yksi keskeisistä teknologisista kehitysaskelista ovat pienikokoiset hyperspektrikamerat, joiden avulla voidaan normaalin valokuvauksen lisäksi tunnistaa kuvasta myös erilaisten pintojen materiaaleja ja ominaisuuksia. Lisäksi tietokoneiden kasvaneen laskentatehon ansiosta isojen tietomassojen käsittelystä ja analysoinnista on tullut monella alalla jo arkipäivää.

Tämän tutkimuksen tarkoituksena on tutkia, millaiset valmiudet hyperspektrikameralla on vianpaikannuslentojen ja kunnonhallinnan tehostamiseksi. Tällä hetkellä tätä toimintaa tehdään operatiivisesti lähinnä droneista, lennokeista ja helikoptereista käsin käyttäen tavallisia värikameroita, lämpökameroita, infrapunakameroita ja/tai laserkeilaimia. Tällä tutkimuksella selvitetään erityisesti hyperspektrikameran käyttömahdollisuuksia sähkölinjojen tarkastustoiminnassa. Tutkimuksessa selvitetään, millaisella järjestelmäkokonaisuudella ja -asetuksilla tarkastustehtävät voidaan toteuttaa, sekä millä tavoin tarkastuksessa kerätystä aineistosta voidaan havaita määritellyt havainnot automaattisesti. Uuden sensoritekniikan käytöllä uskotaan saatavan merkittäviä hyötyjä lentotarkastustoiminnan laadussa ja tehokkuudessa, erityisesti sen uskotaan mahdollistavan tarkastustoiminnan automatisoinnin ja tarkkuuden parantumisen.

Rejlers kävi keväällä 2019 esittelemässä drone-aiheista alustavaa tutkimussuunnitelmaa sähköntutkimuspoolille otsikolla ”voimajohtojen kunnossapito- ja häiriötarkastukset kehittyneellä drone- ja sensoritekniikalla”. Tutkimussuunnitelmaa muokattiin sähköntutkimuspoolin kommenttien pohjalta. Päivitetyssä tutkimussuunnitelmassa keskityttiin uuden sensoritekniikan tutkimiseen ja mahdollisuuksiin sähköjakeluverkkojen vianpaikannuksessa ja kunnonhallinnassa. Työpakettien sisällössä otettiin huomioon sähköntutkimuspoolin osapuolien tarvekuvaukset siitä, mitä tutkimusta ala tarvitsee.

Yhdessä eri alojen asiantuntijoiden kanssa haarukoitiin potentiaalisimmat tarkastushavainnot tutkimuksen kohteiksi. Ideoita tuli paljon, ja osa jouduttiin jättämään tutkimuksen ulkopuolelle. Hyperspektriaineistoa eri havaintoihin liittyen kerättiin laboratorio-olosuhteissa sekä kentällä. Moni havainto karsiutui pois jatkotarkasteluista laboratoriotestien jälkeen.

2 Perusta tutkimukselle

Tutkimuksella pyrittiin selvittämään keinoja tehostaa sähköjakeluverkkojen kunnossapitoa ja kunnonvalvontaa hyperspektrikamerateknologialla varustetuilla droneilla. Uudella sensoritekniikalla pystytään erottelemaan kohteen eri materiaaleja ja niiden ominaisuuksia toisistaan tehokkaalla tavalla. Hyperspektrikameran lisääminen muiden sensoreiden rinnalle (lämpökamera, RGB-kamera, Lidar) parantaa analyysin ja havaintojen tarkkuutta. Uusi sensoritekniikka (LiDAR- ja SWIR-spektrialueen (1000-2000 nm) kamerat) mahdollistavat myös havaintojen tekemisen haastavissa ympäristöolosuhteissa, kuten sumuisessa tai pimeässä säässä.

Tänä päivänä hyperspektritekniikkaa käytetään erityisesti kasvillisuuden tunnistamisessa, jolloin sen käyttökohde voi olla esimerkiksi sähköverkkojen johtokadun vierustan kasvillisuusriskitason määrittelyssä. Tällöin tarkastustoiminnassa voitaisiin havaita, onko johtokadun vierellä mm.

havupuita tai riukumaisia lehtipuita, joiden varaan kerääntyy helposti tykkylunta, jotka pahimmillaan aiheuttavat puun kaatumisen tai oksahaarojen repeytymisen. Hyperspektrikameran käyttöä sähkönjakeluverkon tarkastuksissa ei tosin ole juurikaan tutkittu ja vaatii vielä paljon kehitystyötä, jotta teknologiaa päästäisiin tehokkaasti käyttämään päivittäisessä tarkastustoiminnassa.

Tänä päivänä kaikki rutiininomaiseen ja laajamittaiseen kuntotarkastamiseen ja vianpaikannukseen liittyvä lentotarkastustoiminta tehdään edelleen miehitetyillä ja arvokkailla helikoptereilla. Perinteisellä helikopterilla yksi lentotunti maksaa usein yli 1000 euroa johtuen muun muassa laitteistojen kalliista hankintahinnoista, suuresta polttoaineen kulutuksesta, vaadittavan huollon määrästä sekä vakuutuksista. Lisäksi helikopteria ohjaamaan vaaditaan jatkuvasti yksi hyvin koulutettu lentäjä ja hänen apunaan voi olla myös toinen henkilö joko operoimassa kameralaitteistoa tai tekemässä havaintoja omin silmin. Lentotoiminta ei myöskään ole täysin riskitöntä, joten nämä kaksi henkilöä ovat jatkuvasti vaarassa lentäessään suhteellisen matalalla, lähellä ”kuolleen miehen käyrää”, jonka alapuolella helikopterin pakkolasku autorotaation avulla ei enää onnistu. Onnettomuustilanteissa on myös suuri potentiaali henkilö- sekä omaisuusvahinkoihin.

Erilaisten tarkastus-, kunnossapito- ja korjaustoimien tehostamiseen kannustavat myös lainsäädäntö sekä muuttuva ilmasto. Pääministeri Sanna Marinin hallitusohjelmassa nostetaan esiin tarpeet kehittää vaihtoehtoisia tapoja varmistaa sähkön toimitusvarmuus erityisesti haja-astusalueilla. Niinpä toimet ilmajohtoverkon tarkastus-, kunnossapito- ja korjaustoimienpiteiden tehostamiseen ovat nyt ja tulevaisuudessa tarpeen jo lain vaatimusten täyttämiseksi. Ilmastonmuutoksen on tämän lisäksi arvioitu aiheuttavan yhä kasvavia haasteita, sillä on mahdollista, että erilaiset myrskyt yleistyvät ja voimistuvat myös Suomessa (Lehtonen ym. 2019, Aukia 2017). Ilmaston lämpeneminen vähentää lisäksi roudan määrää, joka todennäköisesti lisää sähkölinjan vierellä olevien puiden riskiä kaatua linjan päälle (Lehtonen ym. 2019).

Lainsäädännön osalta vahvasti sähköverkkojen toimintaympäristöön on vaikuttanut vuoden 2013 Sähkömarkkinalain uudistaminen. Uudistuksen yhteydessä lakiin lisättiin jakeluverkon toiminnan laatuvaatimukseen (luku 6, 51 §) vaatimuksena, että sähköverkossa ei myrskyn tai lumikuorman seurauksena saa asemakaava-alueella aiheutua yli 6 tuntia ja asemakaava-alueen ulkopuolella yli 36 tuntia kestävää keskeytystä. Tämä on käytännössä johtanut sähköverkon mittavaan maakaapelointiin. Harvaan asutussa ja pitkien etäisyyksien Suomessa kaapelointi ei kuitenkaan ole kaikkialla taloudellisesti järkevää, vaan Suomessa on nyt ja tulevaisuudessa paljon ilmajohtoverkkoa, joka on altis myrskyjen aiheuttamille vaikutuksille.

Eri investointivaihtoehdoilla on erilaiset elinkaarikustannukset, jotka riippuvat monista tekijöistä, kuten muun muassa verkkotekniikan kustannuksista, vikojen aiheuttamasta haitasta, sähkön tulevasta kasvusta ja käytetystä korkokannasta. Ilmajohtorakenteiden kohdalla kustannusriskiä tuo myös epävarmuus nykyisin käytettävien kuparikyllästeisten pylväiden pitoajasta. On arvioita, että niiden pitoaika voisi olla vain 30 vuotta, jolloin ilmajohtovaihtoehtojen kokonaiskustannukset nousevat. Kaapelointiin verrattuna leveä johtokatu ja ilmajohto tien varressa ovat harvaan asutuilla alueilla matalatehoisilla johto-osuuksilla on kustannustehokas vaihtoehto. Leveä johtokatu metsässä on erityisen kustannustehokas keino siirtää lopullisen myrskyvarman verkkoratkaisun toteuttamista tilanteessa, jossa olemassa olevalla ilmajohtolla on vielä käyttöikä jäljellä ja sähkön käytön kehittämiseen liittyy merkittäviä epävarmuuksia.

Tarkastajat ja tarkastustoiminta ovat hyvin isossa roolissa sähköverkkojen kunnonhallinnassa. Tarkastustehtävien suorittamiseen vaaditaan vahvaa ammatillista ja monialaista osaamista: on tunnettava erilaiset ja eri ikäiset rakenteet, sekä eri aikakausien vaatimukset. On myös kyettävä erottamaan isot ja pienet ongelmat toisistaan. Alle on listattu eri näkökulmia turvallisuuden näkökulmasta.

Hyvässä tarkastustyöprosessissa sähkölaitteiston elinkaaren ja toimintavarmuuden hallittavuus kasvaa ja sen myötä sähkön toimituksen toimintavarmuus ja laatu paranevat. Palvelutuotannon verkkotautuessa on yhä selkeämmin nähtävissä verkkoyhtiön oman paikallistuntemuksen väheneminen verkosta ja verkon tuntemus nojaa aikaisempaa enemmän tietojärjestelmiin tallennettuihin tietoihin. Kunnonhallinnan tehokkaan toiminnan tueksi tarvitaan tarkat ja yhdenmukaiset kuntotiedot verkosta. Yhdenmukainen tarkastustoiminta luo pohjan laadukkaan kunnonhallinnan toteuttamiseksi. Tarkastustoiminnan roolin nähdään jakeluverkkoliiketoiminnassa kasvavan tulevaisuudessa pääpainon siirtyessä toimitusvarmuusinvestoinneista verkon ylläpitoon.

Sähköturvallisuuslaissa (STL 410/96), Sähköturvallisuusasetuksessa (498/96) ja Kauppa- ja teollisuusministeriön päätöksessä (KTMP 516/96) määritellään sähkölaitteiston haltijan velvollisuudet. Haltija on velvollinen huolehtimaan siitä, että sähkölaitteisto ei aiheuta lain tarkoittamaa vaaraa tai häiriötä ja että sähkölaitteistossa havaitut puutteet ja viat poistetaan riittävän nopeasti. Sähköturvallisuuslaissa 410/96 21§ määritellään vastuut eri tarkastuksien suorittamiseksi. Käyttöönototarkastuksen suorittaa tekijä, joka tehdään kaikille sähköasennuksille. Vastaanottotarkastuksen suorittaa tilaaja, määräaikaistarkastuksen suorittaa viranomaisen (valtuutettu tarkastaja) ja kuntotarkastuksen suorittaa haltija.

Huoltoon ja kunnossapitoon liittyen STL 410/96 10§ määrittää, että sähkölaitteiston haltijan on huolehdittava siitä, että sähkölaitteistossa havaitut puutteet ja viat poistetaan riittävän nopeasti. Sähkölaitteiston suoja-, turva- ja vastaavien järjestelmien määrävällein tehtävää huoltoa vaativien laitteiston osia varten on laadittava ennalta huolto- ja kunnossapito-ohjelma. STL 410/96 12§ mukaan, luokan 3 sähkölaitteistoille ja verkonhaltijan sähköverkolle on tehtävä määräaikaistarkastus viiden vuoden välein.

3 Tutkimuksen toteuttaminen

3.1 Tavoitteet

Tutkimuksen keskeisinä tavoitteina olivat:

- (1) luoda mallit sähköverkossa käytettyjen keskeisien komponenttien spektristä sekä häiriöttömässä (laboratorio-olosuhteet) että häiriötilanteessa (maasto-olosuhteet)
- (2) luoda määrittelyt kerätyn spektriaineiston prosessoinnille ja ohjelmistoalustalle sähköverkoista kerättävän hyperspektriaineiston analysoimiseksi
- (3) luoda ymmärrys vaatimuksista komponenttien ja vikatilojen automaattiselle tunnistamiselle spektrisestä aineistosta
- (4) verrata hyperspektrikameran suorituskkyä tavalliseen värikameratekniikkaan

Tutkimuksen tulokset ovat julkiset. Energia-alan toimijat saavat käyttöönsä tutkimuksessa luodut mallit sähköverkossa käytettyjen keskeisien komponenttien spektreistä sekä häiriöttömässä että häiriötilanteessa, jotka on testattu kenttäolosuhteissa. Tutkimustulokset ovat vapaasti hyödynnettävissä energiatoimialan kehityksen tueksi tulevaisuudessa tutkimuksissa, kehitysprojekteissa ja piloteissa.

Erityisesti tämän uuden sensoriteknologian uskotaan parantavan hahmontunnistuksen ja analyysien tarkkuutta. Uusi sensoriteknologia (LiDAR- ja SWIR- spektrialueen (1000-2000 nm) kamerat) mahdollistavat myös havaintojen tekemisen haastavissa ympäristöolosuhteissa, kuten sumuisessa tai pimeässä säässä.

3.2 Työpaketit

Tutkimuksen toteutus voidaan jaotella tutkimuksen kolmen osakokonaisuuden alle: vaatimusmäärittelyt (työpaketti 1), aineiston keruu ja analyysi (työpaketti 2) sekä aineiston jatkokäsittely (työpaketti 3). Tutkimus rakentuu näiden kysymysten ympärille ja niihin on haettu vastauksia tämän tutkimuksen aikana.

3.2.1 TP1 - Vaatimusmäärittelyt

Hyperspektrikuvausella ja sensoriteknikalla on omat rajoituksensa. Sääolosuhteet, kuten pakkaneen, tuuli, vesi- ja lumisade sekä huono näkyvyys tuovat haasteita myös lentotoimintaan. Selvitetään, mitä vaatimuksia sähkölinjan kunnossapitotarkastustoiminta ja vikapaikkojen havaitseminen asettavat hyperspektrikameralle. Selvitettävänä on esimerkiksi, millaisia vaatimuksia sensoriteknikalle asetetaan mm. lahon tunnistamiseen pylväistä, öljyvuotojen havaitsemiseen muuntajakoneista, SF6-kaasuvuotojen havaitsemiseen ja säievikojen havaitsemiseen. Lisäksi selvitettävänä on mitä vaatimuksia asetetaan kasvillisuuden tunnistamiseen ja luokitteluun johtokadulla, jotta sen viereltä voidaan tunnistaa puulajit, joiden varaan kerääntyy helposti tykkylunta.

Tavoitteena on myös määrittellä, kuinka hyperspektrikameran kyvykkyydet suhteutuvat nykyisin laajamittaisesti käytössä oleviin sensoreihin (RGB, LiDAR, lämpökamera). Selvitetään millaisia vaatimuksia sensorin kiinnitykselle ja kytkennälle on olemassa ja kuinka nykyiset markkinoilla olevat sensorit ja lentoalukset tukevat modulaarisuutta.

Tutkimuskysymykset tutkimuksen vaatimusmäärittelyihin liittyen olivat:

- Mitkä ovat ne viat ja kunnossapitohavainnot, joita hyperspektrikameralla pystytään teoriassa havaitsemaan?
- Mitkä ovat olosuhteet, joissa toimintaa on tarkoitus harjoittaa?
- Mitkä ovat hyperspektrikameran sisältävän sensoripaketin (sis. myös LiDAR, RGB-kamera, lämpökamera) vaatimukset miehittämättömälle ilma-alukselle?

3.2.2 TP2 - Aineiston keruu ja analyysi

Ensimmäisessä vaiheessa tehdään aineiston keruu ja analysointi laboratoriossa, jossa selvitetään millä kaukokartoitusaineistolla mitään eri sähköverkon komponentteja ja häiriöitä pystytään tunnistamaan. Kartoitetaan haasteet, joissa nykysensoriteknikka ei yksistään pysty luomaan riittävän hyvää lähtöaineistoa luotettavan analyysin tekemiseksi. Luodaan spektrometrin avulla mallit ns. spektrisestä tunnuspiirteistä eri komponenteille. Selvitetään millä tavoin erilaisia kunnossapitohavaintoja mm. öljyä, lahoa tai ruostetta pystytään havaitsemaan komponenteista. Kerätty aineisto analysoidaan yhteistyössä FGI:n tutkimusryhmän, sensorivalmistajan ja ohjelmistotuottajan työkaluja hyödyntäen. Spektrometrillä ja RGB-kameralla kerätyn aineiston analyysin avulla luodaan ensimmäiset mallit ns. spektrisestä tunnuspiirteistä eri komponenteille.

Toisessa vaiheessa tehdään aineiston keruu maasto-olosuhteissa maasta käsin, hyödyntäen nosturia tai kytkettynä droneen. Tiedonkeruu tehdään eri ympäristöolosuhteissa kesällä ja talvella Suur-Savon Sähkö-konsernin toimialueella. Järvi-Suomen Energian mahdollistamana tutkimusorganisaatio pääsee turvallisessa ympäristössä kehittämään uusia toimintatapoja ja tuotekehitystyötä hyperspektriteknologian saralla. Maasto-olosuhteissa tehtävässä aineiston keruussa hyödynnetään ja testataan käytännössä ensimmäisessä vaiheessa luotuja malleja komponenttien ja aineiden spektrisestä tunnuspiirteistä.

Tutkimuksessa hyödynnetään mahdollisimman paljon aikaisemmissa tutkimuksissa luotua aineistoa. Hyödynnetään tarvittaessa mm. ECOSTRESS- (Meerdink ym. 2019) ja ASTER- (Baldrige ym. 2009) tutkimusprojekteissa luotuja spektrikirjastoja, sekä FGI:n tutkimusryhmän ja sensorivalmistajien aikaisemmissa tutkimuksissa keräämiä aineistoja.

Selvitetään myös drone-menetelmien haasteita: esimerkiksi miten tarkkoihin resoluutioihin dronella päästään ja aiheuttaako dronen värinä kuvien häiritsevää sumentumista. Eri komponenttien ja vikojen tunnistamista selvitetään regressio- ja koneoppimistekniikoilla.

Tutkimuskysymykset koskien aineistonkeruuta ja analyysia ovat:

- Millä kuvaustaajuudella (kuva/m), resoluutiolla (cm/px) ja spektrikaistoilla (nm) voidaan paikantaa halutut viat tai kunnossapitohavainnot?
- Millä järjestelmäkokonaisuudella tarkastukset ja vianpaikannus voidaan toteuttaa?
- Voidaanko hyperspektrikameralla tehtävää tarkastustyötä tehdä myös yöaikaan?
- Mitä haasteita esim. alustan värinä ja kuvaolosuhteet tuovat mittaukselle?

3.2.3 TP3 - Aineiston jatkokäsittely

Tarkastustoiminnassa luodaan valtava määrä kuva-aineistoa ja mahdollisesti myös muuta dataa, jonka läpi käyminen ihmisvoimin on paitsi erittäin työlästä, myös kallista, ja siten automaattisten tekniikoiden kehittäminen on välttämätöntä. Spektriaineiston analysoinnin haasteena on lisäksi se, että ympäristöolosuhteilla on vaikutusta spektrin tunnuspiirteisiin. Nämä ympäristöstä tulevat häiriöt, kuten mm. auringonvalo, pitää pystyä korjaamaan ohjelmallisesti, koska referenssitaulun saaminen kuvausaineistoon on käytännössä mahdoton tehtävä linjatarkastustoiminnassa. Selvitetään ympäristöolosuhteiden vaikutuksia kerättyyn aineistoon ja erilaisten kalibrointimenetelmien toimivuutta käytännön tilanteissa.

Koska kuntotarkastuksessa valmiin analyysin saaminen ei ole aikakriittistä, voidaan kerätty data purkaa ilma-aluksesta tehtävän päättymisen jälkeen ja analysoida vasta jälkikäteen tehokkailla tietokoneilla. Toinen kohde miehittämättömille ilma-aluksille sähköverkkojen kannalta ovat erilaiset häiriötilanteet, erityisesti suurhäiriöt. Tällaisessa tilanteessa vikapaikkojen nopea löytäminen on ensiarvoisen tärkeää, sillä tällöin korjausresurssit voidaan kohdistaa oikeisiin paikkoihin.

Työvaiheen tavoitteena on ymmärtää, kuinka kerättyä spektristä kaukokartoitusaineistoa pystytään analysoimaan automaattisesti käyttäen hyväksi konenäköä ja tekoälyä. Tutkimuksessa hyödynnetään FGI:ssä kehitettyjä automaattisia Python-pohjaisia prosessointiketjuja, jotka hyödyntävät mm. avoimia scikit-learn ja Tensorflow-paketteja ja erilaisia koneoppimistekniikoita, kuten piirrepohjaiset menetelmät (esim. päätöspuut) sekä keinotekoisia neuroverkkoja, kuten syväoppivat konvoluutioneuroverkot (CNN).

Tutkimuksessa etsitään vastauksia seuraaviin aineiston jatkokäsittelyyn liittyviin tutkimuskysymyksiin:

- Millä koneoppimistekniikoilla tunnistustehtävät voidaan toteuttaa tehokkaasti?
- Millä tavoin lennoilla kerättyä materiaalia voidaan analysoida automaattisesti ja mahdollisesti reaaliaikaisesti?
- Millaisissa tapauksissa havainnointiin voidaan hyödyntää konenäköä ja tekoälyä?
- Minkälaista dataa konenäkö tarvitsee toimiakseen?
- Minkä verran hyperspektrin käyttö parantaa tulkintatarkkuutta verrattuna perinteiseen kameraan? Vaatiiko hyperspektriaineiston analysointi tuekseen myös muita sensoreita (perinteinen kamera, lämpökamera tai laserkeilain)?
- Voidaanko konenäöllä ja tekoälyllä löytää erilaisia vikapaikkoja tarpeeksi luotettavasti?

3.3 Tutkimusorganisaatio

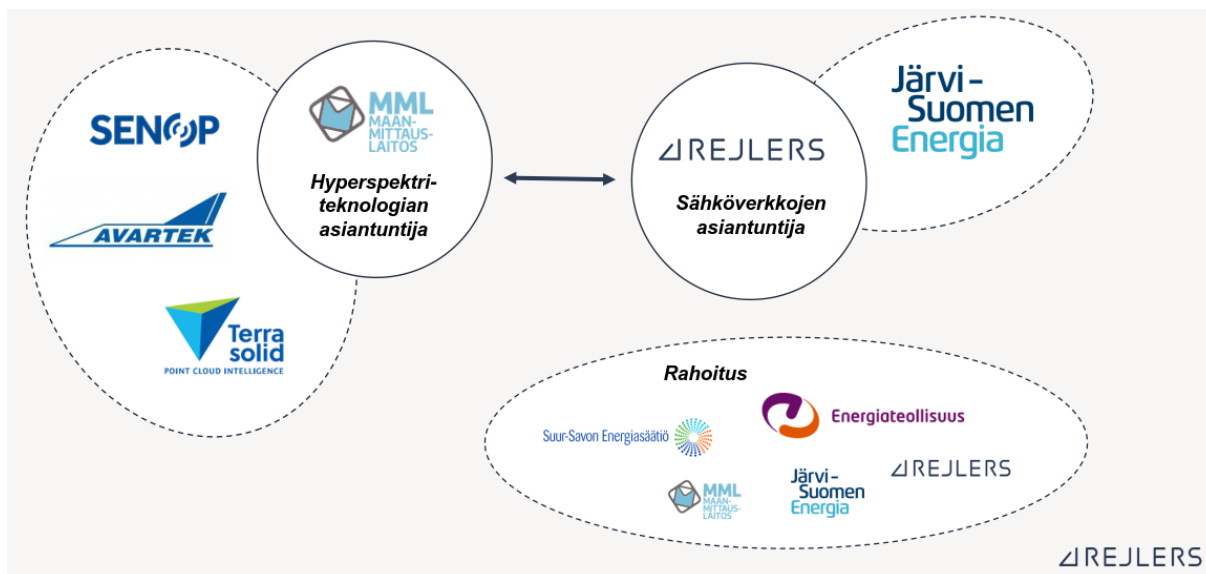
Yhteistyökumppaniverkoston rakentaminen aloitettiin Rejlers Finland Oy:n toimesta jo vuonna 2017. Alla on esitelty tutkimuksen organisoituminen, jossa tutkimuksen pääasiallisina toteuttajina ovat sähköverkkojen asiantuntijapalveluita tuottava Rejlers Finland Oy, hyperspektritekniologian

asiantuntijana Maanmittauslaitoksen T&K-osasto. Lisäksi tutkimukseen osallistuvat sensorivalmistaja Senop Oy, jakeluverkkoyhtiö Järvi-Suomen Energia Oy, dronevalmistaja Avartek Ky, sekä ohjelmistokehityksen asiantuntijana Terrasolid. Tutkimusryhmä on esitetty kuvassa 1.

Tutkimusryhmä kokoontui hankkeen aikana 9 kertaa etäyhteyksin raportoimaan ja keskustelemaan tutkimuksen etenemisestä. Lisäksi hankkeen aikana pidettiin useita projektiryhmän palavereita tutkimuksen toteuttamiseen liittyen.

Tutkimuksen ohjausryhmä koostui seuraavista henkilöistä:

- Tuukka Heikkilä Sähkötutkimuspoolin asiamies (Energiateollisuus ry)
- Tomi Öster Kehityspäällikkö (Järvi-Suomen Energia Oy)
- Tomi Kyhyräinen Käyttö- ja Kunnossapitoinsinööri (Savon Voima Verkko Oy)
- Eija Honkavaara Tutkimusprofessori, TKT (Maanmittauslaitos)
- Esa Haapa-aho Toimitusjohtaja (Terrasolid Oy)
- Jussi Kallio Tuotepäällikkö (Senop Oy)
- Lasse Kankainen Kehitysjohtaja (Rejlers Finland Oy)
- Joonna Ehrnrooth Asiantuntija (Rejlers Finland Oy)
 - hankkeen projektipäällikkö, toimi kokouksissa esittelijänä



KUVA 1. Tutkimusryhmän organisoituminen

Maanmittauslaitoksen Paikkatietokeskus FGI tekee innovatiivista paikkatietoalan tutkimus- ja asiantuntijatyötä. Arvostettu kansainvälinen tutkimuslaitos tarjoaa luotettavaa tietoa yhteiskunnan hyväksi. Paikkatietokeskuksen tutkimus- ja kehitysosasto on tehnyt mittavaa tutkimusta dronepohjaisessa kaukokartoituksessa ja hyperspektrisen aineiston analysoinnissa. FGI:n tutkimusryhmä on johtavia toimijoita kaukokartoituksen ja hyperspektriteknoologiaan liittyvässä tutkimus- ja innovaatiotoiminnassa kansainvälisellä tasolla. Tutkimusryhmällä on käytössään Specimin ja Senopin hyperspektrikameroita (400-1700 nm) ja spektrometreja (400-2500 nm), joita hyödynnetään tässä tutkimuksessa.

Avartek R. Lindberg Ky Kb on tuonut markkinoille uudenlaisen hybrididronen, jonka avulla on pystytty yhdistämään poltto- ja sähkömoottoritekniikoiden edut ja toteuttamaan 2 tuntia lentävä multikopteri. Lisäksi yrityksellä on merkittävä kokemus erilaisista telemetriasovelluksista jo vuodesta 1968.

Avartekin kopteria voidaan koekäyttää projektissa ja saada lisätietoa miehittämättömien ilma-alusten hallinnasta, sekä siitä, millaisia haasteita hyperspektrisensorin lennättäminen kopterissa aiheuttaa.

Senop Oy on suomalainen fotoniiikkayritys, joka kehittää sensoritekniikkaa erilaisiin turvallisuus- ja ympäristösovelluksiin. Heidän tuotevalikoimansa sisältää lämpö-, hyperspektri- ja SWIR-spektrialueen sensorit, joita he ovat luvanneet tutkimushankkeen käyttöön. Senopin sensoria Senop HSC-2 snapshot hyperspektrikamera (500-900 nm) hyödynnetään tässä tutkimuksessa.

Terrasolid Oy on IT-talo, joka kehittää ohjelmistotuotteita ilmasta ja maasta käsin kerättyjen pistepilvien ja kuva-aineistojen käsittelemiseen ja tulkintaan. Terrasolid Oy:n yksi keskeisistä sovellusalueista ovat sähköverkot. Tuotteilla on maailmanlaajuinen levikki. Terrasolid on kiinnostunut hyperspektriaineiston käsittelystä ja ohjelmistoalustan kehittämisestä aineiston visualisoimiseksi ja analysoimiseksi. Terrasolid on hankkimassa dronekäyttöistä hyperspektrikalustoa. Terrasolid osallistuu hankkeen maastokampanjoihin omalla kalustollaan ja lainaa hyperspektrilaitteistoja laboratoriomittauksiin.

Järvi-Suomen Energia Oy huolehtii Suur-Savon Sähkö -konsernin alueella sähköenergian jakelusta yli 102 000 asiakkaalle. Verkkoyhtiön ammattilaiset työskentelevät noin 27 000 kilometrin mittaisen sähköverkoston suunnittelun, rakennuttamisen, käytön ja kunnossapidon parissa. Tutkimushankkeessa maasto-olosuhteissa tehtävät aineiston keruut tehdään Järvi-Suomen Energian verkkoalueella. Verkkoyhtiö on luvannut järjestää mahdollisuuden tehdä tutkimustyötä purkuun menevällä sähköttömällä linjaosuudella.

Rejlers Finland Oy on yksi Pohjoismaiden ja Suomen johtavista insinööritoimistoista. Suomessa yritys on markkinajohtaja sähköverkkojen asiantuntijapalvelutuotannossa. Rejlers tarjoaa monipuolisia insinööripalveluja teollisuuden, rakentamisen, energian ja infran asiakaskunnille. Rejlersin osaaminen on asiakkaiden käytössä kaikissa rakennetun ympäristön elinkaaren vaiheissa asiantuntijapalveluina, projektipalveluina ja jatkuvina palveluina.

3.4 Tutkimusaikataulu

Tutkimuksen aikatauluksi arvioitiin 17 kuukautta. Projektin aikana pidettiin useita tutkimusryhmän tapaamisia sekä Teams-palaverina että kasvokkain, aineiston keräämiseen liittyvät tilaisuudet mukaan lukien.

Tilanneraportointi tehtiin kvartaaleittain, jossa esitettiin projektin tehtävien eteneminen, aikataulujen pitävyys, sekä seuraavaksi suunnitellut tehtävät.

Projektin virstanpylväät:

- Projektin aloitus: syyskuu 2020
- Laboratoriossa kerätyn aineiston analysointi valmis: tammikuu 2021
- Talviolosuhteissa kerätyn aineiston analysointi valmis: toukokuu 2021
- Kesäolosuhteissa kerätyn aineiston analysointi valmis: lokakuu 2021
- Loppuraportointi valmis: joulukuu 2021

4 Aikaisempi tutkimus

Hyperspektrikuvaamista on tähän mennessä tutkittu ja sovellettu mm. kasvillisuuden terveyden analysoinnissa sekä tuotantolinjoilla materiaalien laadunvalvonnassa ja tunnistamisessa. Suomalaiset tutkijat ja yritykset ovat tehneet merkittäviä innovaatioita ja avauksia hyperspektrisen pienoissensoritekniikan alueella. Muun muassa tässä tutkimuksen osapuolena olevan Maanmittauslaitoksen tutkimus- ja kehitysosasto Paikkatietokeskus (FGI) on tehnyt mittavaa tutkimusta dronepohjaisessa kaukokartoituksessa ja hyperspektrisen aineiston analysoinnissa.

FGI:n tutkimusryhmä on johtavia toimijoita kaukokartoituksen ja hyperspektritekologiaan liittyvässä tutkimus- ja innovaatiotoiminnassa kansainvälisellä tasolla.

Hyperspektrisen aineiston hyödyntäminen perustuu kohteen spektrisen signaalin tulkintaan. Spektrisen signaalin tehokkaassa ja laadukkaassa analysoinnissa on tosin vielä haasteita. Luonnonolosuhteissa kerättyyn hyperspektriseen dataan kohdistuu monia häiriöitä, jotka tulee korjata, jotta dataa voidaan analysoida kvantitatiivisesti ja automaattisesti. Muun muassa ”Kvantitatiivista 3D hyperspektristä kaukokartoitusta miehittämättömällä ilma-aluksilla - Teoriasta käytäntöön” –tutkimuksessa on tutkittu ratkaisuja häiriöistä aiheutuvien haasteiden ylipääsemiseksi (Honkavaara ym. 2018). Tutkimuksessa syntynyttä uutta tietoa voidaan hyödyntää hyperspektrikameran soveltamisessa käytännön käyttökohteisiin, kuten sähkönjakeluverkkojen kunnossapitoon ja vianpaikannukseen tässä tutkimuksessa.

Matikainen ym. (2016) tekivät laajan kirjallisuuskatsauksen kaukokartoitusmenetelmien hyödyntämisestä sähkölinjojen ja johtokatuja kasvillisuuden kartoituksessa. Selvityksessä käsiteltiin laajasti kartoitusmenetelmiä satelliittikuvauksesta ilmakuvaukseen sekä maan tasolta tehtäviin kartoituksiin hyödyntäen erilaisia sensoritekologioita. Hyperspektritekologiaan liittyen tutkimusryhmä nosti esiin mm. Frank ym. (2010) tutkimuksen johtokatuja kasvillisuuden kartoituksesta, jossa yhdistämällä hyperspektri- ja LiDAR-aineistoa pystyttiin parantamaan analyysin tarkkuutta tunnistaa kasvillisuutta. Matikainen ym. (2016) totesivat tutkimuksessaan, että hyperspektritekologia avaa lähitulevaisuudessa mielenkiintoisia mahdollisuuksia parantaa puiden ja muiden sähköverkon komponenttien/esineiden automatisoituja analyysimenetelmiä. Qiu, Wu ym. (2019) osoittivat, että hyperspektritekologialla oli selkeä potentiaali eristeiden puhtauden tunnistamisessa. Jusoff ym. (2008) ovat tehneet tutkimusta voimalinjojen kaukokartoituksesta hyperspektritekologialla, jossa tutkimustulokset todistavat, että hyperspektriaineiston käyttö paransi sähkölinjojen ja tornien tunnistamista. Tutkimusta hyperspektrisensorien hyödyntämisestä sähköverkoalalla ei ole mittavasti tehty, ja näin ollen myöskään sähköverkoissa käytetyistä komponenteista ei ole saatavilla mm. niiden spektrisiä tunnuspiirteitäkään, eli ns. ”materiaalin sormenjälkeä”. Vastaavasti esim. ECOSTRESS- (Meerdink ym. 2019) ja ASTER- (Baldrige ym. 2009) tutkimusprojektien tuloksena on luotu yli 3400 spektristä tunnuspiirrettä luonnon materiaaleista ja ihmisen luomista materiaaleista, jotka ovat vapaasti ladattavana verkossa.

Miehittämättömien ilma-alusten käyttöä sähköverkon linjatarkastuksiin on tutkittu Suomessa mm. ST-poolin rahoittamissa hankkeissa vuosina 2014 ja 2017. Vuonna 2014 tehdyissä tutkimuksissa selvitettiin lentorobottien hyödyntämistä sähköverkon tarkastuksissa (Konsulttitoimisto Reneco Oy, 2014a), sekä pilotoitiin erästä miehittämättömää ilma-alusta valokuva- ja pistepilviaineiston keräämisessä (Konsulttitoimisto Reneco Oy ym. 2014b). Vuonna 2017 tehdyssä tutkimuksessa sen sijaan selvitettiin lähinnä kaupallisten edullisten multikopterien hyödyntämistä yksittäisten verkostovikojen paikantamisessa (Konsulttitoimisto Reneco Oy 2017).

Dronejen käyttöä sähköverkojen tarkastustoiminnan autonomisoimiseksi on tutkittu kansainvälisesti useammankin tahon toimesta (mm. He, Zeng ym. 2019; Chen, Yang ym. 2018; Jiang, Jiang ym. 2017). Esimerkiksi Zhang R. ym. (2019) tutkivat voimajohtojen komponenttien automaattista tunnistamista UAV LiDAR aineistosta. Zhang H. ym. (2019) tutkivat puolestaan voimajohtojen tunnistamista UAV:lla kerätystä kuva-aineistosta. Zhang Y. ym. (2017) selvittivät matalalla lentävien UAV:n ja fotogrammetrian hyödyntämistä voimajohtojen tarkastuksissa. Erityisesti huomiota voidaan antaa Zhang F. ym. (2019) tuoreelle tutkimukselle liittyen kaukokartoitusaineiston prosessointimenetelmiin droneilla tehtävän sähköverkojen kunnossapidon näkökulmasta. Myös vikojen havaitsemiseen sähköverkkokomponenteista droneilla on tutkittu monisensorista dataa (Multi Modal) hyödyntäen (Jalil, Bushra ym. 2019). Tutkimusten perusteella voidaan todeta, että dronet/lennokit, uudet tarkat sensorit ja koneoppiminen ovat erittäin lupaavia menetelmiä tarkastustoiminnan automatisoimiseksi.

5 Metodologia

Tutkimuksessa hyödynnettiin olemassa olevaa tietoa sekä aikaisempia selvityksiä ja tutkimuksia aiheeseen liittyen. Tutkimuksessa tehtiin spektriaineiston keruuta kolmessa eri vaiheessa: laboratoriossa (referenssispektrien muodostaminen), sekä maastossa talvella ja kesällä (menetelmän toimivuus käytännön tarkastustoiminnassa). Lisäksi haastateltiin lukuisia asiantuntijoita näkökulman saamiseksi. Tietoja vaihdettiin puhelimitse, Teams-keskusteluissa sekä sähköpostitse.

Ohjausryhmän henkilöiden lisäksi on käyty keskusteluja ja tiedonvaihtoa muun muassa seuraavien henkilöiden kanssa:

- Hannu Boren, puupylväät ja kyllästeet (kehitysjohtaja - Iivari Mononen/ScanPole Oy)
- Karri Häkkinen, lahotarkastukset (yrittäjä - Karri Häkkinen tmi)
- Juho Peura, puupylvästutkimus (tutkimusinsinööri - XAMK/Mikopolis)
- Vesa Malinen ja Jalonen Mikko, voimajohtojen kunnossapito (Fingrid)
- Petri Ahonen., kunnossapitotehtävät (Elvera)
- Jani Turunen, koronakamera (suurjännitelaboratorio – ABB)
- Juha Haakana ja Jukka Lassila (LUT)
- Jarno Virtanen (Nivos Palvelut Oy), Petri Sorjonen ja Timo Korpelainen (Nivos Verkot Oy)
- Arto Hyytiäinen (alueverkkojen kunnossapito – Caruna Oy)
- Juha Rauhalampi, alueverkon kunnossapito (projektipäällikkö, Caruna Oy)
- Tuomo Härkönen, sähköasemien kunnossapito (käyttöinsinööri, Enerva)
- Antti Karjalainen, PAS-linjat (käyttöinsinööri, Enerva)
- Marko Tanninen, hyperspektrikameran käyttötietoja USA/Norja (Suomi Connect)
- Rune Schlanbusch, Senior Researcher (NORCE Norwegian Research Centre AS)

Rejlers Finlandin sisällä on käyty keskusteluja ja haettu lisätietoja jakeluverkon lentotarkastustoiminnasta ja kunnossapidosta seuraavien henkilöiden kanssa:

- Vesa Naukkarinen (Lentotarkastustoiminta)
- Jussi Vitikainen (Kunnossapito/lentotarkastustoiminta)
- Matti Karhinen (Kunnossapito)
- Niko Räsänen (Asiantuntija)
- Jarkko Pekkanen (Lentotarkastustoiminta)
- Veli-Pekka Ahonen (Kunnossapito)
- Kari Mihailov (Sähköasemainsinööri)
- Jari Rinkinen (Projektipäällikkö)

6 Hyödyntämismahdollisuuksien kartoittaminen

Seuraavissa kappaleissa kuvataan yleisesti kunnossapito- ja vianpaikannustoimintaa sähköverkoissa lentotarkastusten näkökulmasta: mitä sähköverkon komponentteja voidaan tarkastella ilmasta käsin ja arvioita siitä, voisiko hyperspektrikameraa käyttää kyseisen komponentin tarkastuksessa tarkastustoimintaan lisäarvoa tuoden.

6.1 Sähköverkkojen tarkastustoiminnan yleiskuvaus

Sähköjärjestelmää voidaan pitää yhteiskunnan kriittisimpänä infrastruktuurina ja sillä on hyvin keskeinen rooli ihmisten perustarpeiden (mm. vesi, ruoka ja lämpö) tyydyttämisessä nyt ja tulevaisuudessa. Tämä rooli asettaa sähköjärjestelmälle hyvin kovat käyttövaatimukset. Eri sähköjärjestelmän osia ovat mm. 400 kV, 200 kV ja 110 kV suurjänniteverkko ja kytkinasemat,

sähköasemat, 20 kV keskijänniteverkko ja kytkinasemat, jakelumuuntamot, 1 kV ja 0,4 kV pienjänniteverkko, sekä viestiverkko sisältäen mm. linkkimastot ja kaukokäyttöerotinasemat.

Jotta verkolle asetetut luotettavuusvaatimukset pystytään saavuttamaan, verkoston eri komponentit on pidettävä toimintakuntoisina mahdollisimman pienillä kokonaiskustannuksilla. Kokonaiskustannukset syntyvät verkostoinvestoinneista, keskeytyskustannuksista, käyttö- ja kunnossapitokustannuksista. Tutkimuksessa keskitytään erityisesti ilmajohtoverkon kunnossapitotoiminnan kehittämiseen, eli miten hyperspektrikameran avulla voitaisiin seurata komponenttien kunnan heikentymistä ja näin ollen ehkäistä vikatilanteiden syntymistä.

Sähköturvallisuussäännöksiensä mukaan avojohtoverkolle on tehtävä kuntotarkastus viiden vuoden välein tai tätä useammin. Tarkastuksessa varmistetaan verkon kunto turvallisuuden näkökulmasta. Tarkempia tarkastuksia tehdään 20 ikävuodesta eteenpäin, kuten mm. pylväiden kunnan tarkastukset. Lähempänä teknistaloudellisen käyttöiän viimeistä ajankohtaa voidaan seurata tehdä lyhyemmällä tarkastusvälillä. Vaikka komponentti olisikin mekaanisesti suunnitellun käyttöikänsä päässä, se voi silti suorittaa sille määritellyn tehtävän, mutta kunnan seuranta kannattaa tehostaa. Oikean toimintatavan määrittely on tehtävä riskejä ja kokonaiskustannuksia arvioimalla.

Komponentteihin keskittyvien toimenpiteiden lisäksi johtokatuja kasvillisuuden raivaus on keskeinen kunnossapitotoimenpide ympäristöstä aiheutuvien vikojen ehkäisemiseksi, kuten mm. taipuisat lehtipuut, jotka lumikuormilla taipuvat linjalle aiheuttaen vian. Hyperspektrikameran näkökulmasta esimerkiksi puulajien tunnistaminen johtokadun reunalta on varsin helppo toimenpide. Hyperspektrin käyttöä kasvillisuuden lajitunnistuksessa ja kasvillisuuden terveyden analysoinnissa on tutkittu ja sovellettu paljon maa- ja metsätaloudessa. Kappaleessa 9.8. on pohdittu hyperspektrikameran hyödyntämismahdollisuuksista puulajien tunnistamisessa.

6.2 Keskeiset tarkistuskohteet lentotoiminnassa

Keskeisten kunnossapito- ja vianpaikannustoiminnan havaintojen määrittelyn perustana tässä tutkimuksessa on käytetty helikopteritarkastustoiminnassa käytettäviä lentohavaintolistauksia. Keskustelun pohjana käytetyssä lentohavaintolistauksissa on listattu sähköverkon komponentti, komponentin toiminto, vikatyypit, vioittumistapa sekä vian vaikutukset. Taulukkojen ja listojen lisäksi mielenkiintoisia tarkistuskohteita ja havaintoja on pohdittu ja tarkennettu keskusteluissa alan toimijoiden ja asiantuntijoiden kanssa.

Alla on listattu keskeisiä havaintotyyppisiä komponentteittain jaoteltuna. Kuvaukset eivät ole täydellisiä ja kaikkia yksittäisiä vikahavaintoja ei ole mainittu; tarkoituksena on avata yleisesti sähköverkoissa kohdattavia vikahavaintoja.

Eristimen tarkoituksena on estää läpilyönnit rakenteisiin. Eristimen posliini- tai lasieristimessä voi olla halkeama, sekä eristinketju voi olla vaurioitunut, jolloin vetoeristimen eristinlautaset voivat haljeta tai irrota kokonaan. Eristimiin on voinut myös kerääntyä likaa tai kasvaa mm. sammalta. Komposiittieristimessä materiaalin hydrofobiset ominaisuudet voi hävitä vuosien saatossa. Eräänä eristinrakennetyypinä on koukkueristin, jossa ei ole erillistä orsirakennetta. Koukkueristimen varsi voi olla taipunut ulkoisen voiman vaikutuksesta. Se on voinut myös irrota pylvään kunnan heikentyessä tai ulkoisen voiman vaikutuksesta. Eristimiin liittyvän vian seurauksena eristimen läpilyöntilujuus heikkenee ja voi aiheuttaa jakelukeskeytyksen, sekä koukkueristimiin kohdistuvien vikojen seurauksena rakenteen kyky kantaa johtimia heikkenee ja lisää myös riskiä jakelun keskeytymiselle.

Erottimien tarkoituksena on erottaa verkon osia toisistaan. Erottimien erotinpiiskat voivat olla vaurioituneet, jolloin katkaisutilanteessa erotin ei toimi oikein, piiskat voivat jäädä jumiin ja pitää yhden tai useamman vaiheen kytkettynä, vaikka erotin olisi ohjattu auki-asentoon.

Harus pitää pylväitä pystyssä. Harusköysi voi katketa esimerkiksi ruostumisen seurauksena. Pylväs kallistuu ja pahimmassa tilanteessa pylväälle tulee liian suuri rasitus ja pylväs kaatuu. Pylvään kaatuminen aiheuttaa turvallisuusriskin ja jakelukeskeytyksen (riippuen johtotyypistä) johtimen putoamisen johdosta.

Johtimen tarkoituksena on johtaa sähköä sähköverkossa. Johtimessa voi olla säievika, jolloin yksi tai useampi johdinsäie katkeaa joko vanhuuttaan tai ulkoisen rasituksen seurauksena. Säievian vaikutuksena johdinsäie purkautuu lyhyeltä matkalta irti johtimesta pienentäen johtimen poikkipinta-alaa ja vähentäen sen kuormitus- ja oikosulkukestoisuutta. Eräissä johdintyypeissä matka voi olla huomattavan pitkä ja johdinsäie voi aiheuttaa oiko- tai maasulun osuessaan muihin rakenteisiin tai maahan. Johdin saattaa olla pudonnut orrelle, kun johdin on irronnut eristinsiteestä. Orrelle putoaminen ei aiheuta välttämättä välitöntä vikaa. Vika aiheuttaa pylvään palamisen kostealla kelillä tai sateella, kun pylvään johtavuus hitaasti paranee.

Johtoalue on ilmajohtoverkolle varattu alue, johon verkon komponentit sijoittuvat. Johtoalue voi olla kaventunut ja sillä voi olla oksimis- tai raivaustarpeita. Tutkimuksen näkökulmasta lehtipuut ovat kiinnostavia kohteita; erityisesti pienet lehtipuut lumikuormien vuoksi. Esimerkiksi johtoalueen reunalla voi olla liian pitkäksi kasvanut puu, joka voi olla altis kaatumaan sähkölinjalle aiheuttaen jakelukeskeytyksen.

Muuntaja muuntaa sähköverkon jännitettä. Ruoste ja öljyvuoto ovat keskeiset vikahavainnot muuntajissa. Muuntajan ruostuminen voi aiheutua mekaanisesta vauriosta tai materiaalin heikosta laadusta. Puhki ruostuessaan eristeenä toimiva öljy voi valua maahan ja aiheuttaa muuntajan vikaantumisen sekä ympäristöhaittoja. Öljyvuoto voi aiheutua ruostumisen lisäksi myös muusta mekaanisesta vauriosta tai huonosta tiiveydestä esimerkiksi läpivienneissä tai muissa tiivisteissä. Muuntajan öljyn pinnan tason laskiessa ja öljyn korvautuessa ilmalla muuntajan sisäinen läpilyöntilujuus laskee ja altistaa muuntajan hajoamiselle, jopa palamiselle ja räjähtämiselle. Myös ympäristöhaitta on mahdollinen.

Orsirakenne kannattelee eristimiä ja johtimia. Orsi voi olla vääntynyt, jolloin orren kiinnitykset pettävät pylvään heikentyessä tai ulkoisen voiman vaikutuksesta. Orsi voi olla myös ruostunut mekaanisen vaurion, materiaalin heikon laadun tai ympäristön olosuhteiden johdosta. Vian seurauksena orsirakenteen kyky kannatella johtimia heikkenee ja altistaa sähkönjakelun keskeytykselle.

Puupylväs on Suomessa yleisin kannatinrakenne keskijännite- ja pienjänniteverkossa. Sähkö- ja teletilastojen mukaan Suomessa on käytössä ilmajohtorakenteissa noin 7 milj. kpl puupylvästä, josta noin 5 milj. on sähköyhtiöiden verkossa.

Pylväs kannattelee muita verkon rakenteita. Pylväs voi olla lahonnut, kyllästysaineen pitoisuus voi olla laskenut tai pylväs on voinut säilyä siihen pylväskengillä kiivettäessä ja muiden ulkoisten vaikutusten seurauksena, jonka johdosta pylvään rakenteellinen vahvuus heikkenee. Kyllästysaineen pitoisuuden laskun tai säilytymisen johdosta myös pylvään vanheneminen nopeutuu. Pylvään latva altistuu sääilmiöille, jonka johdosta se ajan mittaan alkaa lahota ja halkeilla. Pylväshatun puuttuminen nopeuttaa tätä ilmiötä. Latva voi olla myös tikan koloilla: tikat käyttävät latvassa olevia halkeamia käpyjen syömiseen kiilaamalla kävyn halkeamaan. Pylvään latvan ympäri menevä harusköysi kuristaa pylvään latvaa, jolloin puhutaan haruskuristumasta. Edellä mainittujen johdosta latvarakenne heikkenee.

Pylväät kyllästetään niiden käyttöiän pidentämiseksi ja merkittävä osa Suomen pylväskannasta on kyllästetty 50- ja 60-luvuilla. Vuoteen 2006 saakka yleisimmin käytetty pylväs Suomessa on ollut CCA-kyllästeinen (kupari, kromi, arseeni) puupylväs. Vuonna 2006 lainsäädäntö kielsi kyseisen kyllästeen käytön, jonka jälkeen sähköyhtiöt siirtyivät käyttämään kreosootti- ja C-kyllästeisiä (kupariyhdiste) pylväitä. (Hannu Boren, 2010; Verkostosuositus RJ 33:09)

Varoitusmerkinnät. Hengenvaara-kilpi varoittaa avojohtojen vaarallisuudesta ja lentovaroitusmerkit pylväissä varoittavat risteävää johtoa. Johtoalueella voi olla myös muita varoitustauluja, joiden mekaaninen kunto voi olla huono, ne puuttuvat tai ovat rikki. Kilpiä ja merkkiä paikallaan pitävät naulat saattavat esimerkiksi perääntyä vanhetessaan ja aiheuttaa kilven irtoamisen pylvästä.

6.3 Hyperspektrikameran mahdollisuudet tarkastuskohteittain

Eri toimijoiden kanssa käydyissä keskusteluissa syntyneitä ajatuksia purettiin projektiryhmän (Järvi-Suomen Energia Oy, Savon Voima Verkko Oy, Paikkatietokeskus, Rejlers Finland Oy) seurantalavereissa, joissa mahdollisia kiinnostavia havaintotyyppisiä peilattiin hyperspektrikameran etuihin ja haasteisiin. Eri toimijoiden kanssa käydyissä keskusteluissa esiin tuli lukuisia hyviä ideoita tutkimuskohteiksi, mutta joita ei kuitenkaan tämän tutkimuksen puitteissa pystytty ottamaan tarkempaan selvitykseen tai hyperspektrin suora hyöty todettiin pieneksi.

Havaintotyypeistä keskustellessa arvioitiin, mitkä näistä ovat tutkimuksen aikataulun ja resurssien puitteissa mahdollista toteuttaa. Eritoten lahoaminen, ruoste ja öljy olivat paljon keskustelun alla. Myös esimerkiksi johtimien rakenteellisen kunnan analysointi vikatilanteiden jäljiltä sekä hiushalkemien ja kasvuston tunnistaminen eristimistä olivat kiinnostavia tilanteita, joita olisi tarpeellista tutkia. Alla yleisiä kommentteja hyperspektrikameran käyttömahdollisuuksista tarkastustoiminnassa komponentteittain.

Muuntajakone: Ruosteen tunnistaminen olisi hyvinkin mahdollista hyperspektrillä. Ruoste muuntajakoneen viereisessä ympäristössä ei ole haaste - kuvasta voidaan luokitella komponentit (tukitangot, muuntajakone, kiristimet yms.), jonka jälkeen voidaan esimerkiksi erottaa muuntajakoneen ulkopuoliset komponentit pois analyysistä. Hyperspektrillä voidaan mm. luokitella muuntajakoneen päältä värimuutoksen syy: onko värimuutoksen syy öljyvuoto, eläinperäinen lika tai muu lika.

Muuntajan öljyvuoto voi olla hyvinkin muuntajakoneen pohjassa, joten tarkastustoiminnan yhteydessä pitää pystyä kuvaamaan myös mahdollista öljyistä maata muuntajan alla.

Pylväs: Hyperspektrikameralla näkee vain pylvään pintakerroksen, n. 1 mm syvyydeltä pylvään pinnasta. Lähtökohtaisesti pylväät eivät ole tuoretta puuta, vaan ne kyllästetään eri aineilla, jotka vaikuttavat pylvään heijastusspektriin. Pylväillä on myös erilaisia lahoamistapoja, kuten pinta- ja sydänlaho. Hyperspektrillä voidaan tutkia ainakin pintalahoja, mutta ei osattu vielä arvioida, muuttaako pylvään lahoaminen pinnan rakenteita siten että muutos olisi hyperspektrikameralla nähtävissä.

Kysymyksiä heräsi pylvään lahoamisprosessista ja siitä, minkälaisia kemiallisia reaktioita syntyy, kun pylväs lahoaa. Pylvään lahoamisprosessia pohdittiin esimerkinomaisesti maatuvaan aineen spektrin muutoksien kautta. Lehdet esim. ovat ensin hyvin eläviä ja kuihtumisvaiheessa niiden spektrissä tapahtuu muutoksia ”red-edge”-alueella. Kun puu tai pylväs lahoaa, tapahtuuko siinä jotain vastaavaa prosessia, jolla voisi ennustaa lahon syntymistä? Tätä kysymystä pohdittiin kyllästysaineen pitoisuuden näkökulmasta. Spektristä todennäköisesti pystyttäisiin näkemään missä elinkaaren vaiheessa pylväs on tarkastelemalla kyllästysaineen pitoisuuden laskua pylvään pinnasta. Todennäköisesti kyllästeet ovat tunnistettavissa spektrillä, mutta mitä tapahtuu ajan saatossa? Projektiryhmän keskusteluissa päädyttiin siihen, että tämä näkökulma vaatisi paljon aineistoa ja näytteitä pylväistä.

Hyperspektrikameran hyödyntämisestä puupylväiden kunnan analysoinnissa on kiinnostuttu myös ulkomailla. Norjalaiset olivat esitelleet viime vuonna tutkimustyötään Whispers konferenssissa 2019 liittyen puupylväiden lahoamisen analysointiin: **(1)** Boyan Yuan; Arnoud Jochemsen; Nabil Belbachir (2019) *“Remote sensing of gases for rot detection in wooden utility poles”*, **(2)** Arnoud Jochemsen; Gry Alfredsen; Ingunn Burud (2019) *“Short wave infrared hyperspectral image analysis of Scots pine wood affected by decay fungi”*.

Eristimet: Hiushalkeman tunnistaminen eristimestä olisi mielenkiintoinen havainto, koska sitä ei näe helikopterista. Pohdittiin, tapahtuuko eristimen pinnassa hiushalkeman johdosta mahdollisesti jokin muutos, joka näkyisi hyperspektrillä. Tästä ei ollut kokemusta, joten asia otettiin tutkittavaksi. Otettiin selvitetäväksi myös läpi lyöneen eristimen pinnan muutoksia hyperspektrillä. Myös sammaleen kasvu tai muu biologinen kasvusto eristimen pinnassa on mahdollista tutkia. Pinnasta otetusta hyperspektrikuvasta on helposti havaittavissa kasvillisuus ja muu biologinen materiaali.

Fingridin kanssa käydyssä tapaamisessa esiin nousi komposiittieristimien kunnan tarkastelu. Fingrid asennutti vuonna 2009 ensimmäiset komposiittieristimet Keminmaa-Petäjäskoski asemavälin voimajohdolle. Komposiittieristimistä ei ole vielä paljon kokemuksia, mutta niissä voisi olla kiinnostavaa tutkia hydrofobisien ominaisuuksien muutosta, likaisuutta ja reikiä eristimen pinnassa. Hydrofobisuuden/silikonikuoren ideana on hylkiä likaa, sillä jos eristimen pinta ei puhdistu normaalisti mm. vesisateiden avulla, eristimen läpilyöntilujuus heikkenee. Tutkimuksen kannalta haastavaa on saada erityisesti eri kunnossa olevia komponentteja aineiston keruuseen, varsinkin näin lyhyellä aikataululla. Edellä mainitun haasteen vuoksi, päätettiin että tätä havaintotyyppiä ei pystytä ottamaan tähän tutkimukseen jatkoon, vaikka hyvin mielenkiintoinen kohde olisikin.

Vanhoissa eristimissä on sisällä erillinen "täyteaine", joka saattaa ajan mittaan rapistua ja tippua. Tämä johtaa siihen, että lumikuormilla eristin pomppaa irti. Täyteaineen ("tuppi") voidaan nähdä eristimen alta tapin reiästä, mutta pitää päästä katsomaan läheltä. Hyperspektrikamera voisi tuoda lisäarvoa siten, että voitaisiin ennakkoon nähdä tämän "täyteaineen" rapistuminen ja luokitella sen kunto analysoimalla sen pinnassa tapahtuvia muutoksia. Suurena haasteena on saada otettua tarkastuksen yhteydessä kuva kyseistä kohteesta. Tämä havaintotyyppi todettiin sellaiseksi, että kyseistä kohtaa ei pystytä kuvaamaan tarkastuksen yhteydessä, joten havaintotyyppiä ei tutkittu enempää.

Säievika: Säieviassa suoraan ei tapahdu sellaisia havaintoja, joita voitaisiin hyperspektrikameralla havaita. Muun muassa johtimen rautasydämen näkyminen ei ole todennäköistä, kun johdin alkaa purkautumaan. Säievika nähdään ilmasta käsin myös varsin helposti värikameralla ja ihmissilmin. Toki maasta käsin taivasta vasten tarkastellessa säievika on vaikea havaita tai erottaa taustan johdosta. Johtimissa voi olla myös palojälkiä vikatilanteiden jäljiltä. Elveran kanssa käydyssä keskustelussa säievika voisi olla kiinnostava erityisesti siitä näkökulmasta, että voitaisiinko tutkia johtimen rakenteen heikentymistä analysoimalla palojälkeä: muuttuuko johtimen metallin ominaisuus vikatapahtumassa siten, että sen rakenteen heikentymisen voisi havaita hyperspektrikameralla.

Lehtipuut: Lehtipuut ja erityisesti pienet lehtipuut olisivat mielenkiintoinen tutkimuskohde lumikuormien vuoksi. Lehtipuut voidaan tunnistaa muusta puustosta ottamalla RGB-kameralla kuvat lehdettömään ja lehdelliseen aikaan. Keskenkasvuiset puut kiinnostavat, esimerkiksi latvuksen koon perusteella voisi tehdä analyysia puun koosta. Kuvaus tapahtuu linjatarkastuksessa viistosta, jolloin voidaan saada myös runko kuvattua, joka auttaa lajin tunnistuksessa. Hyperspektrikamera parantaa puulajiluokittelua: sillä voidaan helposti luokitella havupuut ja lehtipuut. Johtokadun reunan puustoanalyysin mukaanottoa harkittiin, mikäli sille jäisi tutkimuksessa aikaa. Lopulta päädyttiin siihen, että tätä havaintotyyppiä ei saada sisällytettyä aineiston keruun vaiheisiin, mutta arvioidaan teoreettisesti hyödyntämismahdollisuuksia.

Kuura: Kuuran muodostumista sähköverkon komponentteihin havainnoidaan lentotarkastuksilla. SWIR-alueen kameralla kuuran muodostumista pystyttäisiin teoriassa havainnoimaan. Tutkimuksen kannalta on hyvin haastavaa saada luotua ja ylläpidettyä kuuran muodostumiselle otollisia olosuhteita kuvauslaboratoriossa. Käytännössä jos tämän tyyppisiä havaintoja halutaan havaita, aineiston keruu pitäisi tehdä kenttäolosuhteissa.

Kaapelipääte: Elveralta tuli mainintana mahdollinen tutkittava havainto siitä, onko pylvääseen nouseva kaapelinpääte vetäytynyt. Havainto pitäisi hyperspektrillä olla helposti havaittavissa, koska kaapelin eri kerroksissa käytetään eri metalleja. Kylmäkutistekaapelipääteissä on ollut ongelmana,

että pääte halkeaa saumakohtastaan. Hyperspektristä ei kuitenkaan nähty juurikaan hyötyä halkeaman tunnistamiseksi.

Ylijännitesuoja: Kiinnostavana vikahavaintona esitettiin PJ-ylijännitesuojan rikkoutuminen. Ylijännitesuojia on ennen vanhaa asennettu viimeiselle pylväälle ennen liittymää. Niiden rikkoutumista/laukeamista ei välttämättä näe ihmissilmän. Joitain palojälkiä, nokea tai vastaavaa voi näkyä tai kyseessä voi olla vain mekaaninen rikkoutuminen komponentin sisällä.

Orsirakenne: Eräissä kunnossapidon keskusteluissa nousi esiin alumiiniorien väsyminen. Orsi on voinut saada rasiinasta esimerkiksi liian tiukasta kiristyksestä tai kaatuneen puun takia. Orsi voi väsyä joltain kohdalta (vaalenee hieman heikentyneeltä kohdalta) ja lopulta jossain vaiheessa murtuu kokonaan. Alumiinioria ei ole enää paljon verkossa, eikä uusia asenneta. Tämän takia ne jätettiin tutkimuksen ulkopuolelle.

PAS-linja: PAS-linjan katkeamisia on tapahtunut Järvi-Suomen Energian alueella noin kerran vuodessa. On epäilty, että katkeamiskohtaan olisi joskus aiemmin salama lyönyt. Aihe olisi tutkittavissa hyperspektrikameralla, mutta tarvittavaa näyteainestoa on vaikeaa saada.

Erötin: Jakeluverkon erottimen koskettimien huonokuntoinen välyys voi aiheuttaa erotinvaurioita ja sähkön laatuhäiriöitä laajalla alueella. Jos virtatien kosketin ei ole tarpeeksi kiinni, koskettimet hiljalleen palaavat, hitsaavat ja sulavat. Piiskan näkee maasta, mutta itse päävirtatien kuntoa tai asentoa ei läheskään aina. Jos pää- ja apukosketin ovat huonolla kontaktilla, jossain vaiheessa alkaa tapahtua lämpenemistä ja hitsaamista. Tällöin pinnoilta pitäisi löytyä huonon kontaktin aiheuttaman palamisen jäljiltä ”röpelöä”. Pohdittiin pystyisikö hyperspektrikameran avulla havaitsemaan tämän vaurion tehokkaasti.

Eräissä erotintyyppissä on ollut keskustelujen mukaan valmistusvirhe, jonka vuoksi niiden käyttöikä on jäänyt vain pariin vuoteen. Käytännössä vikaantumisen on jälkeen päin tehtyjen selvitysten perusteella johtunut komponentin asentamisesta sille sopimattomiin ympäristöolosuhteisiin. Keskusteluissa epäilynä on ollut, että osittaispurkaukset alkavat nakertamaan eristeeseen onkaloita ja lopulta seuraa läpilyönti. Komponentin pintaan tulee ajan saatossa kellertäviä läikkeitä, mutta niiden puistaaminen ei ole auttanut asiaan. Hajonnut komponentti ionisoi ilman, jonka johdosta kaikkien kennojen erottimet on vaihdettava. Tämä olisi mielenkiintoinen havaintotyyppi hyperspektrille, mutta aineiston saaminen on haastavaa tutkimuksen puitteissa.

Latvahatut: On helposti nähtävissä, onko pylvään latvassa hattu vai ei. On havaittu, että hattuja puuttuu paljon. Havainto näkyy helposti myös valokuvasta ja on hyvin havaittavissa RGB-kameralla otetusta kuvasta. Hattujen puuttuminen ei aiheuta juuri toimenpiteitä.

6.4 Tutkimukseen valitut havaintotyytit

Lopulta tutkimukseen valittiin yhdeksän havaintotyyppiä. Valintojen arvioinnin perusteena oli, että

1. ne ovat keskeisiä sähkönjakeluverkon kunnossapito- ja vianpaikannustoiminnan turvallisuuden tai käyttövarmuuden kannalta
2. hyperspektrikamera tuo lisäarvoa kyseisiin havaintoihin
3. niitä mahdollista tutkia tutkimuksen toteutukseen varatuilla resursseilla ja aikataululla.

Valitut havaintotyytit olivat seuraavat:

1. Muuntajakoneen ruoste
2. Muuntajakoneen öljy
3. Pylvään laho
4. Eristimen hiushalkeama (epävarma, mutta kokeillaan labraolosuhteissa)
5. Eristimen vaurio, läpilyönti
6. Eristimen pinnassa oleva kasvusto
7. Kaapelipäätteen vetäytyminen pylväsnousussa

8. Johtimen säievian ennakointi palojälkeä analysoimalla (epävarmaa muuttuuko johtimen koostumus siten, että rakenteen heikontumisen voisi havaita hyperspektrikameralla, mutta päätettiin kokeilla havaintoa labraolosuhteissa)
9. PJ-ylijännitesuojan rikkoutuminen (epävarma, mutta päätettiin kokeilla havainnon tunnistamista labraolosuhteissa)

7 Kaukokartoituksen rajoitteet ja ominaisuudet

Hyperspektrikuvaukseen, sensoriteknikkaan ja lentotoimintaan rajoitteita aiheuttavat esimerkiksi sääolosuhteet. Lisäksi kohteiden tunnistamisessa ja luokittelussa on omat rajoitteensa. Tutkimuksessa perehdytään näihin rajoitteisiin sähkölinjan kunnossapitotarkastustoiminnan ja vikapaikkojen havaitseen näkökulmasta.

7.1 Sääolosuhteiden vaikutus lentolaitteisiin

7.1.1 Lämpötila

Pikkupakkanen ei yleensä ole ongelma millekään lentolaitteille. Virallinen tuki loppuu yleensä, laitteesta riippuen joko 0°C tai -10°C, mutta jos akut ovat lämpimät, jokseenkin kaikki järjestelmät toiminevat myös kylmemmässä. Jäätävä sää, joka kerryttää jäätä lentolaitteen pintaan, saattaa olla vakava ongelma varsinkin pitkäkestoisille BVLOS (*Beyond Visual Line of Sight*, dronen lennättäminen näköyhteyden ulkopuolella) lennoille, mutta tuskin yleinen ongelma lyhyemmällä VLOS (*Visual Line Of Sight*, dronen lennättäminen näköyhteydessä) lennoilla. Liika kuumuus ei ainakaan Suomessa ole merkittävä ongelma.

7.1.2 Tuuli

Multiroottoridronejen suurin lentonopeus (*max airspeed*) on yleensä noin 15-17 m/s. Multiroottoridronet voivat siis operoida noin 8-12 m/s tuulessa, mutta puuskaisessa säässä tuokin on jo korkea keskituuli. Laskeutuminen voi olla haasteellista. Kokemuksen mukaan isoja droneja voidaan lennättää 7 m/s tuulennopeuksilla, mutta siitä kovemmat tuulet ovat jo riskitekijä.

Kiinteäsiipisten dronejen suurin lentonopeus on yleensä ainakin 30 m/s. Ne voivat siis lentää helposti 15 m/s tuulessa. Jopa 20 m/s on useilla laitteilla sallittuna. Laskeutuminen voi jopa olla pehmeämpää vastatuulessa, mutta puuskainen tuuli on riskitekijä.

7.1.3 Vedenkestävyys (vesisade/lumisade/sumu)

Vedenkestäviä droneja löytyy helposti markkinoilta sekä multiroottori- että kiinteäsiipi- (*fixed wing*) tyyppisinä. Nämä pystyvät lentämään ongelmitta ainakin kevyessä vesisateessa. Vedenkestävyys ei kuitenkaan yleisesti ole kaikkien dronejen vakio-ominaisuus.

Vedenkestävyys ei kuitenkaan välttämättä tarkoita, että dronea kannattaa säännöllisesti ehdoin tahdoin lentää sateessa. Vaikka ohjauselektronikat ovatkin turvassa, moottorit voivat kastua ja tämän aiheuttama lisääntynyt korroosio heikentäneen niiden elinikää/luotettavuutta. Eli sateeseen päätyminen on näillä järjestelmillä kestettävissä, mutta rutiininomainen vesisateessa lentäminen ei ole hyväksi dronelle.

Dronerungoissa joitain ratkaisuja löytyy myös kameroiden vedenpitävyyteen, mutta koteloinnit painavat ja lisäävät vääristävän ikkunan kameran ja kohteen väliin. Ikkunaan voi tulla pisaroita.

Ilmassa oleva vesi voi haitata monia datalinkkejä ja lyhentää datalinkin kantamaa, joka voi vaikuttaa BVLOS käyttöä. Sopivalla taajuudella toimivalla datalinkillä tämäkään ei ole ongelma. GPS signaali toimii säässä kuin säässä. Ilmakehässä oleva vesi heikentää signaalia, mutta ei yleensä niin paljon, että aiheuttaisi havaittavaa tai vakavaa turvallisuusongelmaa. (Mehaffey 2021)

7.1.4 Huono näkyvyys (sumu, sade, lumisade, savu, pimeys)

Näkyvyys ei teknisesti ole ongelma useimpien dronejen lentämiselle, jos lennetään (ja kiinteä siipisellä lennokilla myös laskeudutaan) GPS-reittipisteiden (*GPS waypoint*) avulla. Huono näkyvyys on kuitenkin aina turvallisuusriski ja rajoittaa maksimietäisyyttä, jolla drone voidaan lennättää VLOS lainsäädännön piirissä. Pilotti ei pysty välttämättä huomaamaan tai estämään törmäystä esimerkiksi puuhun, sähkölinjaan, tai toiseen lentolaitteeseen. Hätälaskeutumisen hallinta vian sattuessa on myös erittäin hankalaa huonossa näkyvydessä.

7.2 Sääolosuhteiden vaikutus sensoreihin

7.2.1 Optiset kamerat

VIS, NIR ja SWIR-aallonpituusalueella (1.1 - 3 um) pidemmät aallonpituudet antavat aina paremman näkyvyyden, koska Rayleigh-sironta häiritsee silloin vähemmän. Pienet hiukkaset, kuten savu tai sumu sirottavat näkyvää valoa, mutta SWIR-alueen säteily kulkee lähes häiriöttä.

Yöllä, uuden kuun aikaan ainoa valonlähde on käytännössä ilmakehän hohde (*airglow*). Piikennoihin tai InGaAs-kennoihin perustuvat NIR/SWIR sensorit pystyvät joissain olosuhteissa tarjoamaan lähes saman suorituskyvyn kohteen havaitsemiseen kuin lämpökamerat, kunhan kohde ei ole täysin varjossa tai pilvisyys ei ole erityisen paksua (Vollmerhausen ym. 2013).

Taulukossa 1 on kuvattu VIS-, NIR- ja SWIR-aallonpituuksien käyttökelpoisuutta eri olosuhteissa päivänvalossa.

Passive Day Comparison of Vis, NIR, SWIR	VIS	NIR	SWIR
1. Maritime Haze Penetration	Red	Yellow	Green
2. Fog Penetration	Red	Red	Red
3. Atmospheric Transmission	Red	Yellow	Green
4. Cloud Penetration	Red	Red	Red
5. Forrest Fire and Fog Oil Penetration	Red	Yellow	Green
6. "See" Laser Designator Spot	Yellow	Yellow	Green
7. Camouflage Detection/Identification	Yellow	Yellow	Yellow
8. Urban and Rural Background Contrast	Green	Green	Yellow
9. Maritime and Ground Target Contrast	Yellow	Green	Green
10. Driving and Pilotage			
11. Skin Detection	Yellow	Yellow	Yellow
12. Spectral Discrimination	Yellow	Yellow	Green
13. Turbulence	Yellow	Yellow	Green
14. Long Range Identification (3 inch Aperture Soldier)	Yellow	Yellow	Green
15. Long Range Identification (6 inch Aperture Platform)	Red	Yellow	Green

TAULUKKO 1. VIS (0.4-0.7 um), NIR (0.7-1.0 um) ja SWIR (1.0-1.7 um) aallonpituusalueiden hyödyllisyys päivällä erilaisissa olosuhteissa. (Vihreä = Hyödyllinen, Keltainen = Jonkin verran hyödyllinen, Punainen = Ei hyödyllinen) (Driggers ym. 2013)

Taulukon 1 tiedot avattuna:

1. Utu (haze): muodostuu hyvin pienistä partikkeleista ja sillä on pienempi optinen tiheys kuin sumulla. Pidemmällä aallonpituuksilla sumun optinen tiheys on pienempää.
2. Sumu (fog): vesipartikkelit ovat suurempia kuin VIS/NIR/SWIR-aallonpituudet. Vasta LWIR-aallonpituudet voisivat nähdä jotain sumun läpi.
3. Ilmakehän läpäisevyys (sisältää absorption ja sironnan): pitkillä etäisyyksillä (useampi kilometri), SWIR-alueella voi olla jopa kymmenkertaisesti parempi ilmakehän läpäisevyys kuin VIS-alueella.
4. Pilvet: samat ominaisuudet kuin sumulla.
5. Savu (valkoinen savu on tyypillisesti peräisin palavasta puusta, musta savu öljystä): musta savu on optisesti paksumpaa kuin valkoinen. SWIR-aallonpituusalue on selvästi paras, NIR parempi kuin VIS.
6. Laserpointteri: 0.85, 1.06 tai 1.55 μm
12. Lyhyillä etäisyyksillä eri aallonpituusalueilla ei ole eroa spektrien erottuvuudessa. Pitkillä, useiden kilometrien etäisyyksillä, SWIR on parempi johtuen paremmasta ilmakehän läpäisevyydestä.
13. Turbulenssi (lämmöstä johtuva väreily): aiheuttaa kuvan sumentumista ja vääristymää.


Kuvassa 2 DigitalGlobe WorldView3 -satelliitin näkyvän valon kuva (ylempi kuva) sekä kolmen SWIR-kanavayhdistelmän kuva (alempi kuva) Kalifornian metsäpaloista elokuussa 2014. Satelliitissa on 8 SWIR kanavaa 1195 nm - 2365 nm alueella. Alemmassa kuvassa hyödynnetään erityisesti kanavaa 8, joka kattaa aallonpituusalueen 2295 - 2365 nm.



KUVA 2. DigitalGlobe WorldView3 -satelliitin ottamaa kuvaa Kalifornian metsäpaloista. (Maxar Technologies 2014)

7.2.2 Lidar

Lidar-kuvauksessa kohde valaistetaan lyhyellä laserpulssilla, ja heijaste kuvataan synkronoidulla herkällä kameralla. Kuvausgeometriasta johtuen kuvassa ei ole lähes ollenkaan varjoja, ja kuva voidaan tarkentaa eri kohteisiin ja eri etäisyyksille. Käytetyt laseraallonpituudet ovat NIR, 780 - 900 nm, tyypillisimmin 808 - 880 nm, sekä silmäturvallinen SWIR alue, noin 1.4 - 2.2 um. Menetelmällä on mahdollista nähdä ainakin ohuen sumun ja savun läpi. (Laurenzis & Christnacker 2013)



KUVA 3. Velodyne VLP-16-LiDAR kuvaamassa savun läpi (Fritsche ym. 2016)

7.2.3 Lämpökamera

Lämpökamerat toimivat sekä päivällä että yöllä, ja myös vaihtelevissa sääolosuhteissa. Käytetyt aallonpituusalueet ovat MWIR (3 - 5 μm) sekä LWIR (8 - 13 μm). Lämpökameran havaintokykyyn vaikuttaa erityisesti kohteen ja taustan välinen lämpötilaero (Perić ym. 2019).




KUVA 4. Drone-lämpökamera näkee sumussa paremmin kuin RGB kamera, mutta heikentyneesti kuitenkin. (sUAS.com 2018)



KUVA 5. Lämpökamera toimii hyvin myös vesisateessa. (ACTi Corporation 2016)

7.2.4 RGB-kamera

Digitaalisen värin mittaaminen ja tuottaminen perustuu RGB-värimalliin, eli esimerkiksi tavallinen digitaalikamera tallentaa kuvan RGB-muodossa. RGB-värikuvatiedosto muodostuu kolmesta värikanavasta (punainen, vihreä ja sininen). Komponentteina on kolme pääväriä, joiden sekoitussuhde ratkaisee esitettävän värin. Tyypillisesti digitaalisissa sovelluksissa käytetään yhtä tavua, eli 8 bittiä ilmaisemaan kunkin päävärin voimakkuutta, jolloin jokaisella päävärillä on käytettävissään arvoja välillä 0-255. (Stone 2016)



KUVA 6. RGB-värimalli: päävärit punainen, vihreä ja sininen sekä sekundaariset värit keltainen, turkoosi ja magenta.

8 Hyperspektrimenetelmät

8.1 Laitteistot


Kohteiden spektrejä mitattiin seuraavilla MML:n laitteistoilla:

- **ASD FieldSpec 4** on kenttäspektrometri jolla voidaan mitata pistemäisten kohteiden heijastuspektrejä hyvällä tarkkuudella lähes koko auringon valon aallonpituuskaistalla 350-2500nm.
- **MicaSense RedEdge** on kevyt multispektraalinen dronerkaukokartoituskamera joka kerää kuvia viidellä kapealla kanavalla (490nm, 555nm, 665nm, 715nm, 840nm) jotka on optimoitu erityisesti kasvillisuuden kaukokartoitukseen.
- **Senop Rikola HSI** on Fabry–Pérot Interferometri-filteriin perustuva hyperspektrikamera jonka spektrikaistat voidaan valita ohjelmallisesti kunkin tehtävän tarpeiden mukaan väliiltä 500-910nm.

- **Specim AFX17** on SWIR alueella (900-1700nm) kuvaava pushbroom-spektrimetri joka on kehitetty erityisesti dronekäyttöön. Pushbroom-spektrimetri ei siis kuvaa suoraa tavallista 2D kuvaa vaan mittaa spektrejä viivalta dronen alla. Dronen lentäessä eteenpäin spektrimetri "skannaa" maastosta kuvan.



KUVA 7. Hankkeessa käytetyt hyper- ja multispektraaliset mittalaitteet: ASD FieldSpec 4 kenttäspektrimetri, MicaSense RedEdge-M multispektrikamera. Senop Rikola HSI hyperspektrikamera, ja Specim AFX17 pushbroom-spektrimetri.



KUVA 8. MicaSense RedEdge-M kameran kanavien spektrivasteet

TAULUKKO 2. Senop Rikola HSI-kameran kanssa käytettyjen spektrikanavien keskiaallonpituuden ja FWHM leveydet.

Center	FWHM	Center	FWHM	Center	FWHM	Center	FWHM	Center	FWHM
504.28	6.36	593.37	6.18	684.56	6.66	773.71	4.30	863.54	9.46
512.91	7.26	601.40	6.49	693.97	6.82	782.85	5.95	873.07	9.21
521.48	7.47	611.64	7.64	701.60	5.01	792.18	5.80	881.51	9.55
530.75	6.75	620.27	8.30	711.43	4.43	800.88	6.46	890.21	9.03
539.46	7.42	628.86	7.05	720.08	4.97	809.82	5.67	899.16	9.58
548.45	6.64	643.80	6.76	728.95	3.92	818.49	6.62	908.17	8.90
557.59	7.35	648.67	6.58	738.01	4.86	828.84	9.05		
566.28	6.47	657.82	7.58	746.76	4.11	837.57	10.16		
575.31	7.02	666.88	6.72	756.03	4.49	846.22	9.24		
583.98	6.60	676.21	7.52	764.56	3.67	855.44	9.93		

8.2 Esiprosessointimenetelmät

Sekä kenttäspektrometri sekä kamerat mittaavat valon määrää, joka osuu sensoriin. Kaikissa tutkimuksen mittalaitteissa on valmiina valmistajan radiometrinen kalibraatio joilla raakakuvat voidaan muuttaa radiansseiksi, mutta MicaSense RedEdge ja Senop Rikola HSI:n kohdalla tämän tarkkuus on todettu riittämättömäksi. Tämän vuoksi näiden kameroiden kuvat prosessoitiin radianssikuviksi käyttäen Paikkatietokeskuksen mittaamia omia radiometrisia kalibraatiota. Rikola-kameran osalta kalibrointi- ja prosessointimenetelmä on esitetty artikkelissa (Suomalainen ym. 2021).

Senop Rikola kameran hyperspektrikuvaus perustuu sähköisesti säädettävään Fabry-Perot-interferometri suodattimeen. Kamera valottaa eri värikanavat peräjälkeen noin 10-20ms välein. Tutkimuksessa käytettiin kamera-asetuksia, joilla kerätään datakuutio yhteensä 46:lla eri värikanavalla välillä 504nm and 809nm. Kameran perättäisistä valotuksista johtuen datakuution kuvat eri värikanavilla eivät ole täydellisesti päällekkäin, jos kamera tai kohde liikkuu valotussarjan aikana. Normaalaa kaukokartoituskäyttöä varten Paikkatietokeskuksessa on kehitetty ortorektifikaatiomenetelmä, jossa kuvien keskinäiset orientaatiot ratkaistaan ortokuvien

fotogrammetrisen prosessoinnin yhteydessä (Honkavaara ym. 2017). Tämä fotogrammetrinen menetelmä ei kuitenkaan ole sovellettavissa yksittäisten datakuutioiden suoristamiseen, joten jouduimme hankkeessa kehittämään konenäköratkaisun kuvien alignointiin. Kehitetty ratkaisu perustuu OpenCV-algoritmeihin, joilla jokaisen yksittäisen värikanavan kuvaa verrataan referenssikanavan kuvaan ja tämän suoristamiseen löydetään Euklidiset muunnosparametrit. Kehitetty Python-scripti löytyy tämän raportin liitteenä, nimellä *Rikola_AlignRadianceBSQ.py*. Tämän alignoinnin jälkeen eri värikanavat ovat lähes pikselin tarkkuudella päällekkäin ja datakuutiosta voidaan luotettavasti analysoida ja/tai irroittaa spektrejä.

8.3 Kaukokartoitus-signaalit

Sekä kenttäspektrometri sekä kamerat tuottavat spektrejä radianssi-yksiköissä, joka ei yleisesti ole suoraa käytettävissä tulkinnessa koska signaalitasot ja spektrien muodot riippuvat suoraa valaistuksen määrästä sekä valon valkotasapainosta. Tämän vuoksi tällaisten mittalaitteiden keräämät radianssispektrit muutetaan useimmiten reflektansseiksi, useimmiten käyttämällä valkeaa ja/tai harmaita reflektanssireferenssipaneeleja (*ELM, Empirical Line Method*). Reflektanssiyksiköissä lukemat skaalautuvat siten että 0 vastaa täysin mustaa kohdetta ja 1 vastaa mattaa valkeaa pintaa. Tämä skaalaus myös suoristaa spektrit myös siten että valaistuksen väri ei vaikuta enää merkittävästi spektrimuotoon.

Paneeleilla suoritettava reflektanssimuunnos on toteutettavissa tarkasti sekä laboratoriomittauksissa että kentällä esimerkiksi kuvatessa siistiä tasaista maanpintaa. Sähköverkon kohteilla ELM reflektanssimuunnokseen liittyy kuitenkin merkittäviä epävarmuuksia. Maastoon vaakasuoraan asetetuilla paneeleilla voidaan määrittää tarkasti kokonaissäteily, joka tulee auringosta ja ilmakehästä, mutta menetelmä ei pysty määrittämään valon määrää tai tarkkaa väriajakaumaa, joka osuu esim. pystysuoran pylvään etelä tai pohjoispuolelle. Tämän vuoksi ELM-menetelmä ei tuota tarkkoja reflektanssiarvoja muille kuin vaakasuorille puhtaasti valaistuille pinnoille ja esim. varjostuneiden kohteiden spektrien reflektanssiarvot jäävät matalammiksi kuin täysin valaistujen pintojen.

Suoraa valaistut ja varjostuneet pinnat saavat myöskin eri suhteessa suoraa auringon valoa verrattuna sinisestä taivaasta, pilvistä, ja ympäröivästä maastosta heijastuneeseen valon määrään. Koska näiden valaistuskomponenttien spektrit poikkeavat toisistaan, on varjostuneisiin pintoihin tuleva valo eri väristä kuin mitä suoraa valaistuille pinnoille tulee. Tämä aiheuttaa sen, että eri tavoin kallistuneista pinnoista havaitut reflektanssispektrit voivat poiketa jonkin verran toisistaan myös spektrimuodon osalta vaikka kohde olisikin samanlainen joka puolelta.

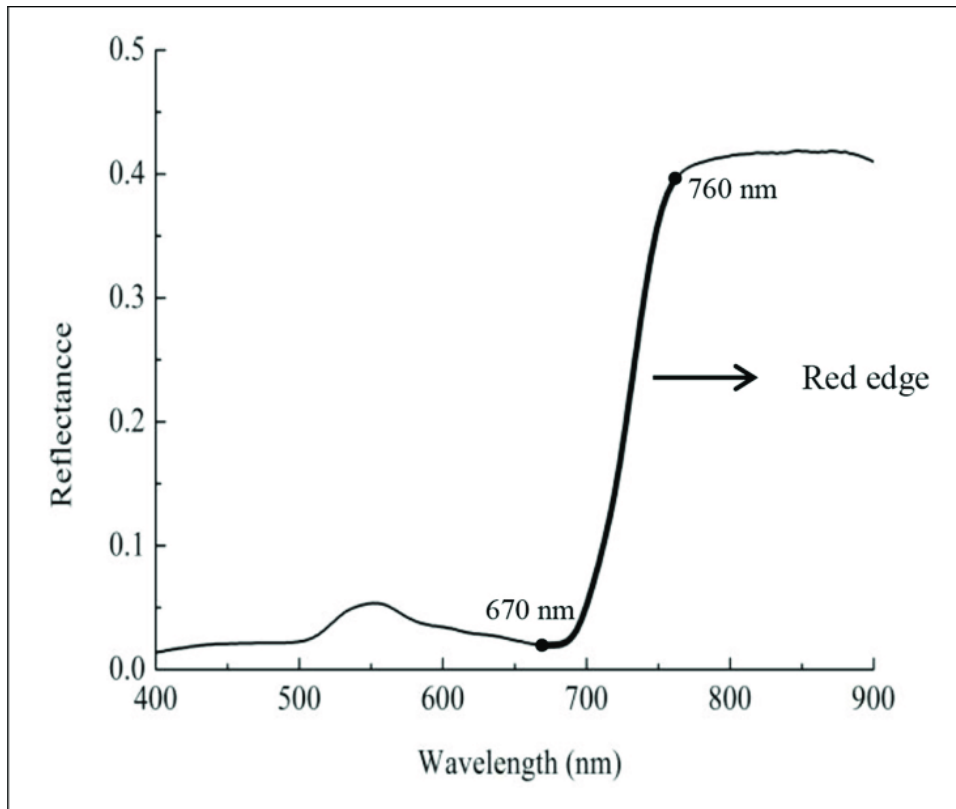
Nämä epävarmuudet spektrien kirkkaudessa ja spektrimuodossa aiheuttaa sen, että kaukokartoitusmenetelmillä kohteiden tunnistamisessa ei välttämättä voi käyttää yksinkertaisimpia tulkintamenetelmiä, jotka perustuvat esimerkiksi kohteen kirkkauteen yhdellä tietyllä kanavalla. Tämän sijasta sovellettavien menetelmien tulee perustua hyperspektrisiin signaaleihin, jotka normalisoivat itsensä riippumatta kohteen kirkkaudesta ja pienistä spektrin värivirheistä.

Eräs yleisimmistä tällaisista signaaleista on NDVI (Normalized Difference Vegetation Index):

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

NDVI käyttää kohteen kirkkautta kahdella värikanavalla, lähi-infrapuna ja punainen, ja laskee näistä yksiköttömän indeksin. Tällä tavoin laskettu indeksi ei riipu lainkaan suoraa kohteen kirkkaudesta vaan sen arvoon vaikuttaa ainoastaan spektrin muoto. NDVI:n arvo vaihtelee -1 ja +1 välillä ja reagoi herkästi kasvillisuudessa ja orgaanisessa materiaalissa esiintyvään red-edge-signaaliin (Kuva 9).

Kasvillisuuden kaukokartoituksessa NDVI antaa yleisesti selkeästi positiivia arvoja kasvillisuudelle ja kasviperäiselle materiaalille, kun taas epäorgaanisten kohteiden NDVI on yleensä noin nollan tuntumassa. NDVI:tä voidaankin käyttää helposti orgaanisten kohteiden erottamiseen epäorgaanisista.



KUVA 9: Tyypillinen kasvillisuuden reflektanssispektri. “Red edge”-nousu 700nm ympärillä on signaali, joka löytyy lähes kaikista kasvi- ja eläinperäisistä orgaanisista aineista. (kuva: Guo et al. 2018, <https://doi.org/10.3389/fpls.2018.00675>)

NDVI on kehitetty erityisesti tutkimaan kasvillisuuden red-edge-signaalia, mutta käyttäen eri värikanavia voidaan vastaavalla matemaattisella kaavalla luoda myös muihin spektri-ilmiöihin reagoivia indeksejä, joiden arvo ei riipu kohteen näennäisestä kirkkaudesta.

9 Aineiston keruu ja jatkokäsittely

Tutkimuksessa hyödynnettiin olemassa olevaa tietoa sekä aikaisempia selvityksiä ja tutkimuksia aiheeseen liittyen. Tutkimuksessa tehtiin spektriaineiston keruuta kolmessa eri vaiheessa: laboratorioissa (referenssispektrien muodostaminen), sekä maastossa talvella ja kesällä Järvi-Suomen Energian verkkoalueella (menetelmän toimivuus käytännön tarkastustoiminnassa).

Lentokokeita valmistelevat maasto- ja laboratoriomittaukset suoritettiin pääasiassa ASD FieldSpec spektrometrillä koska tällä saatiin mitattua laadukkaimmat spektrit parhaiten kontrolloiden näiden mittauskohdat. Lentokokeissa sekä osassa maasta mitatuista käsikäyttöisissä testeissä käytettiin dronkameroita.

Tarkempiin alkuvaiheen tutkimuksiin laboratorioon kuvattavaksi pyrittiin hakemaan aikaisemmassa vaiheessa valituista havaintotyypeistä sellaisia verkkorakenteita, jotka ovat yleisimpiä nykypäivän sähköverkossa. Niinpä marras-joulukuun 2020 aikana MML:n laboratorioon toimitettiin seuraavia verkkokomponentteja: pylväsnyytteitä, muuntajakoneita, erottimia, eristimiä, johtimia, PJ-ylilyännitesuojia, kuumakutistepäätteitä ja muuntajaöljyä. Komponenttien spektrit kuvattiin hyperspektrikameroilla laboratorio-olosuhteissa. Tutkimus jatkui spektriaineiston analysoinnilla.

Maastossa spektrejä kuvattiin ensimmäisellä kerralla Mikkelissä Otavan sähköaseman varastointipaikalla sekä Mäntyharjulla Elveran toimipisteellä muuntajakoneiden osalta (28.10.2020). Tämän jälkeen suoritettiin maastossa kerätyn spektriaineiston analysointi.

Seuraava maastokäynti toteutettiin kaksipäiväisenä (23.-24.3.2021), jolloin kuvaukset painottuivat puupylväisiin. Kuvauspäiviksi valittiin päivät, jolloin olisi ideaaliset sääolosuhteet lentotoiminnalle, jotta saadaan laadukasta aineistoa: noin -2...+2 astetta, ei lumisadetta, jotta lumet ovat pois pylväistä. Lisäksi lentotoiminta ajoitettiin keskipäivälle valoisaan hetkeen. Kuvassa 10 näkyy päivän säätila ja itse drone hyperspektrikameroineen.

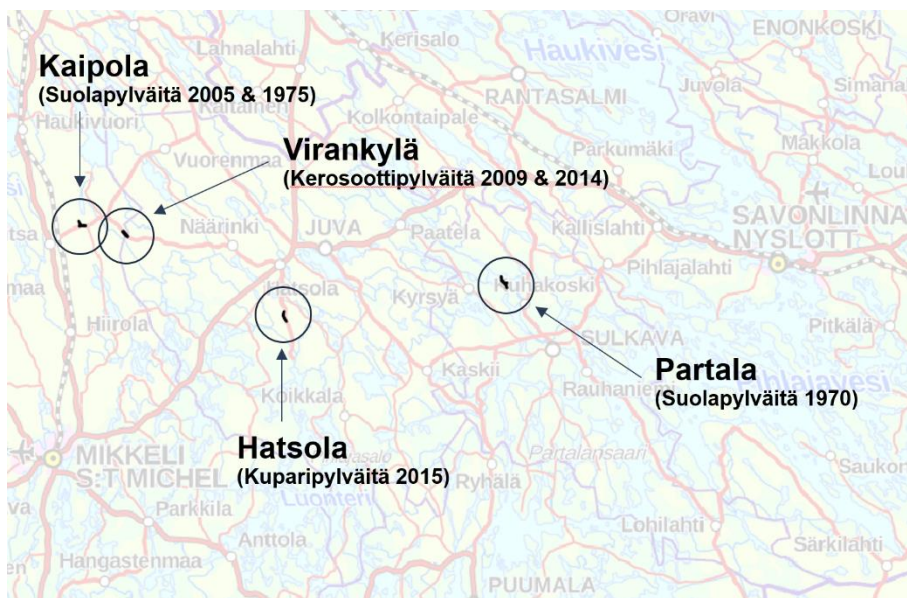


KUVA 10. Toinen maastokäynti maaliskuussa 2021. Kuvassa DJI M600 dronea ja siihen kiinnitetty AFX17 hyperspektrikameraa valmistellaan kuvauslentoa varten.

Laboratoriotesteissä oli havaittu, että suolapylväistä on tunnistettavissa muutos, jonka tunnistaminen onnistuu VNIR-alueen kameralla. Kreosoottipylväistä on tunnistettavissa mahdollinen muutos, jonka tunnistaminen tarvitsee SWIR-alueen kameran. Kuparipylväisiin liittyen tarvittaisiin lisää dataa.

Pylväät todettiin mielenkiintoisimmaksi ja hyödyllisimmäksi tutkimussuunnaksi. Kenttäkokeissa etsittiin vastausta korreloivatko hyperspektrikuvauksen tulokset linjalle tehdyn lahotarkastuksen millimetreihin.

Idealiaisia kohteita etsittiin Järvi-Suomen Energian verkkoalueelta pylväiden perusteella. Kohteissa olisi myös muita komponentteja tarjolla tarkasteltavaksi. Valikoituneet kohteet on esitetty kuvassa 11.



KUVA 11. Toisen maastokäynnin kuvauskohteina olleiden pylväiden kyllästetyypit ja sijainnit Järvi-Suomen Energian verkkoalueella.

Maastokäynneillä kerätyt aineistot toimitettiin analysoitaviksi MML:lle.

Seuraavissa kappaleissa eritellään jakeluverkon tutkimuskohteet ja käydään läpi hyperspektrikuvauksen hyödynnettävyyttä kyseisten havaintojen kohdalla. Tutkittavaksi valittiin keskeisiä verkkokomponentteja.

9.1 Puupylväiden kunto

Puupylväiden kunto

Puupylväiden kunnan tulkitseminen hyperspektrikameralla tuli hyvin monissa keskusteluissa esiin ja tutkimussuuntana osoittautui toimijoita eniten kiinnostavaksi. Toisaalta idean toimivuus herätti myös epäilyjä.

Tutkimuksen aikana pohdittiin näkökulmaa useammasta suunnasta. *Minkälaisia kemiallisia reaktioita syntyy, kun pylväs lahoaa? Miten voisi ennustaa lahon syntymistä? Lahoamisprosessia pohdittiin mm. maatuvan aineen spektrin muutoksien kautta. Lehdet esim. ovat ensin hyvin eläviä ja niiden spektrissä tapahtuu hyvin tunnistettava infrapuna-alueen red edge-spektrimuodon suoristuminen. Kun puu/pylväs lahoaa, niin tapahtuuko siinä jotain vastaavaa prosessia?*

Keskustelua käytiin myös mm. pylvään varren kuntoon liittyen: *Pystyykö varren kuntoa luokittelemaan esim. analysoimalla kyllästeaineen määrää suhteessa lahoon? Korreloiko pylvään maanpäällisten osien spektri lahovaurion syvyyden kanssa?*

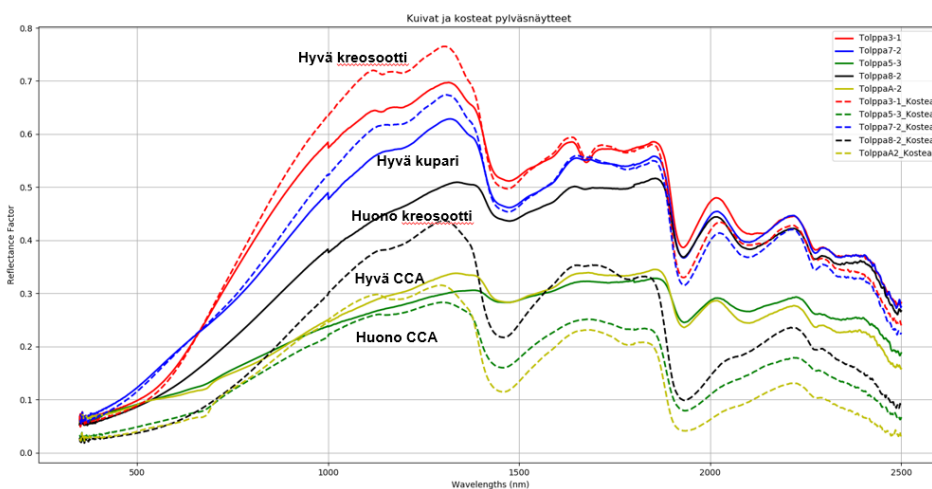
Hyperspektrikuvaus on yleisesti ottaen herkkä mittaamaan kemiallisia muutoksia rakenteissa ja koska lahotessaan pylvään kemiallinen rakenne muuttuu lähtökohtaisesti lahoonhavainnointi voisi olla

johon hyperspektrikuvaus soveltuisi. Ongelmana on kuitenkin, että hyperspektrikameralla havainnoi, ihmissilmän tavoin, vain aivan pylvään ulkopintaa eikä suora havainnointi syvemmistä kerroksista ole mahdollista. Pylvään rakenteellinen lujuus kuitenkin riippuu pääasiassa pylvään sisäosien kunnosta. Tutkimuksen aikana selvisi myös että, kaukokartoitukselle hankalasti, lahovauriot syntyvät pääasiassa ainoastaan pylvään maanalaisiin tai aivan maanrajassa oleviin osiin, eli kohtiin, jotka eivät yleensä ole suoraa näkyvissä ilmasta. Lisäksi pylväät eivät ole lähtökohtaisesti tuoretta puuta, vaan ne kyllästetään eri aineilla, jolloin eri kyllästeillä pylväillä on erilainen spektri. Lisäksi jokainen pylväs on omanlaisensa yksilö. Pylväillä on myös erilaisia lahoamistapoja, kuten pinta-, katkosydänlaho. Myös erilaisia lahottajasiemeniä on olemassa. Näiden haasteiden vuoksi käytännössä ilmakuvauksella (hyperspektri tai muu optinen menetelmä) ei ole mahdollista suoraa havaita lahovauriota, vaan havainnointiin tulee käyttää epäsuoria menetelmiä.

9.1.1 Hyperspektrisignaalien tunnistaminen laboratoriossa

MML laboratorioon toimitetuilla pylväsnäytteillä suoritettiin kattavat laboratoriomittaukset. Pylväät oli luokiteltu käytetyn kyllästeen (CCA, Kreosootti, CCB) ja pylvään lahosyvyuden perusteella. Laboratoriossa kustakin pylväsnäytteistä mitattiin heijastusspektrit käyttäen ASD FieldSpec 4 spektrometriä sekä 1000W Oriel QTH laboratoriovalolähdettä. Näytteitä oli 19:sta pylvästä yhteensä 54 tolpanpätkää.

Puupylväiden kosteus vaikuttaa näiden heijastusspektreihin. Mittausten alussa kaikki näytteet olivat erittäin kuivia koska näitä oli säilytetty sisätiloissa jo vähintään useita päiviä tai jopa viikkoja. Näytteiden kosteustaso on todennäköisesti vastaava kuin kesällä pitkän kuivan hellejakson jälkeen. Kosteuden vaikutusta spektreihin tutkittiin valituilla 5 näytteellä (hyvä&huono CCA, hyvä&huono kreosootti, hyvä CCB) suorittamalla mittaukset ensin "kuivina". Näytteiden kosteuttamiseksi nämä kasteltiin vesihanalla ja suljettiin yön yli muovipusseihin imemään kosteutta itseensä. Seuraavana päivänä pussit avattiin ja mitattiin heti täysin "märkinä". Tämän jälkeen näytteiden annettiin kuivua vähintään 30min niin että pinnoilla ei ollut vesipisaroita, ja näytteet mitattiin uudestaan "kosteina" (Kuva 12).

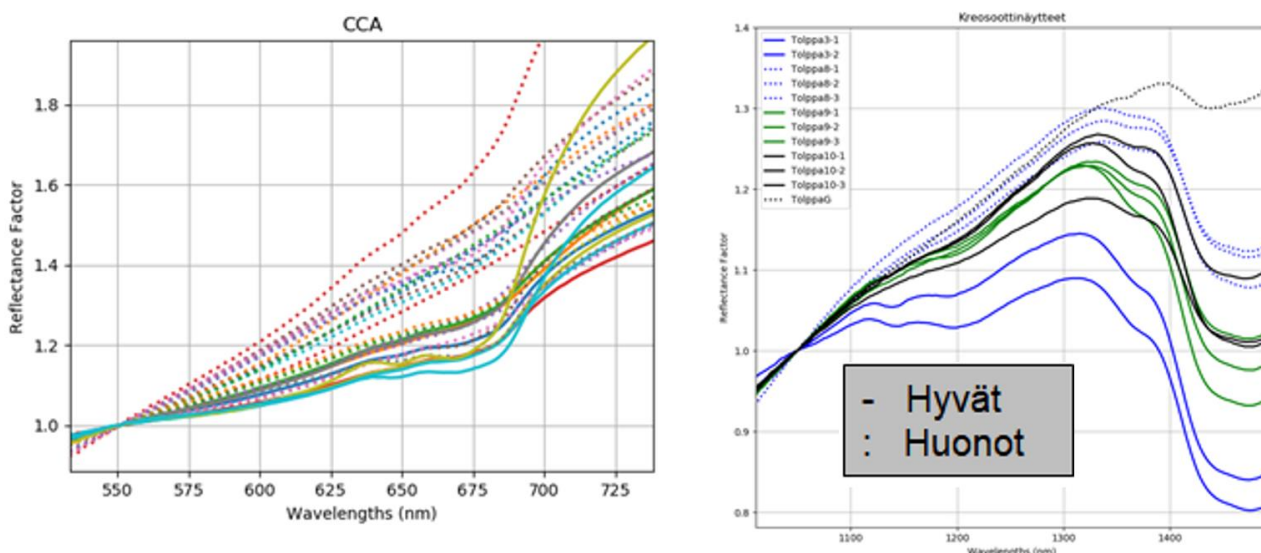


KUVA 12. Kosteuden vaikutus kyllästettyjen pylväiden heijastusspektreihin. Yhtenäiset viivat on mitattu erittäin kuivista pylväsnäytteistä, kun katkoviivat on mitattu samoista näytteistä yön-yli kostuttamisen jälkeen.

Kostutettujen näytteiden reflektanssispektrit olivat systemaattisesti matalampia kuin kuivien näytteiden. Pääasiassa spektrien muodot säilyivät samankaltaisina kosteudesta riippumatta, mutta

suhteellisesti tummenema on suurempi jo valmiiksi tummilla spektrialueilla. Spektrimuodossa kosteuspitoisuus vaikuttaa eniten 1450nm ja 1900nm absorptiovyöhykkeillä, jotka liittyvät juurikin vesimolekyylien absorptioaallonpituuksista, sekä näkyvän valon alueen matalan reflektanssin alueilla. Hyväkuntoisten kreosootti- ja kuparipylväiden näilläkin aallonpituuksilla ei näy merkittävää muutosta, kun taas vanhempien ja huonokuntoisempien pylväiden osalta vaikutus on merkittävästi isompi. Tämä voi selittyä uusien pintojen kovuudella ja vanhojen pintojen "sienimäisyydellä" joka vaikuttaa pintojen vedenimeytymisominaisuuksiin.

Spektreistä voidaan havaita myös kuinka eri kyllästeaineiden heijastusspektrit poikkeavat toisistaan. CCA pylväillä on selkeä porrasmainen spektrimuoto 670nm ympärillä, jonka perusteella se voidaan hyperspektrikameralla erottaa muista kyllästeistä. Kreosootti- ja CCB-pylväiden spektreissä ei ole VNIR alueella (<1000nm) havaittavissa vastaavia selkeitä kapeita spektrimuotoja, mutta yleisesti kuparipylväissä reflektanssispektri kääntyy selkeään nousuun jo lyhyemmällä aallonpituuksilla siirryttäessä näkyviltä aallonpituuksilta NIR alueelle.



KUVA 13. Hyvä- ja huonokuntoisten CCA- ja kreosoottipylväiden spektrejä laboratoriossa kuvattuna. Yhtenäiset viivat ovat hyväkuntoisia näytteitä ja katkoviivalla huonoja näytteitä.

Hyvä- ja huonokuntoisia pylväitä vertaillen havaittiin että suola- ja kreosoottikyllästetyille pylväille tarvitaan eri kuvausmenetelmät.

CCA-pylväillä 670nm:n spektrimuodon vahvuuden havaittiin korreloivan pylvään laatuluokan kanssa (Kuva 13) ja hypoteesiksi muodostettiin, että näiden spektrialueiden kuvaamisella voitaisiin arvioida CCA pylväiden kuntoa. Täysien hyperspektrimenetelmien lisäksi CCA-kyllästetyille pylväiden kuntoa pystyisi todennäköisesti kuvaamaan VNIR-multispektrikameralla, tai jopa jo RGB-kameralla. Mahdollisia indeksejä voisivat olla esim. Seuraava NDVI-tyyppiset itsenormittuvat indeksit:

$$I = \frac{R_{Red} - R_{Green}}{R_{Red} + R_{Green}} \quad I = \frac{R_{Red} - \frac{1}{2}(R_{Green} + R_{NIR})}{R_{Red} + \frac{1}{2}(R_{Green} + R_{NIR})}$$

Kapeakaistaisella multispektrikameralla optimaalinen punaisen kanavan keskiaallonpituus on noin 670 nm. Vihreän ja NIR kanavan täsmällisellä aallonpituudella ei pitäisi olla kovin suurta merkitystä menetelmän toimivuudelle. Ensimmäinen Red-Green-NDVI indeksi olisi periaatteessa mitattavissa

jo suoraa RGB kuvilta, mutta kameran punaisen kanavan tarkkaspektrivaste voi vaikuttaa indeksin toimivuuteen. Kasvillisuuden mittaukseen tarkoitetuista multispektrikameroista esim. MicaSense RedEdge:n punainen kanava osuu erittäin hyvin halutulle aallonpituudelle.

Kreosoottipylväillä koko VNIR alueelta (<1000 nm) ei löytynyt käyttökelpoisia kuntosignaaleja, vaikkakin huonot pylväät olivat absoluuttisesti tummempia kuin hyvät. Tällainen kirkkauteen perustuva signaali on kuitenkin kaukokartoitusolosuhteissa vaikeasti tulkittava eikä todennäköisesti käyttökelpoinen. SWIR alueella 1000-1300nm vyöhykkeellä havaittiin laboratorionäytteissä selkeä korrelaatio näyteiden kunnon ja spektrikäyrän kallistuskulman välillä. Tätä signaalia voidaan tulkita esim. käyttäen seuraavaa itsenormittuvaa indeksiä:

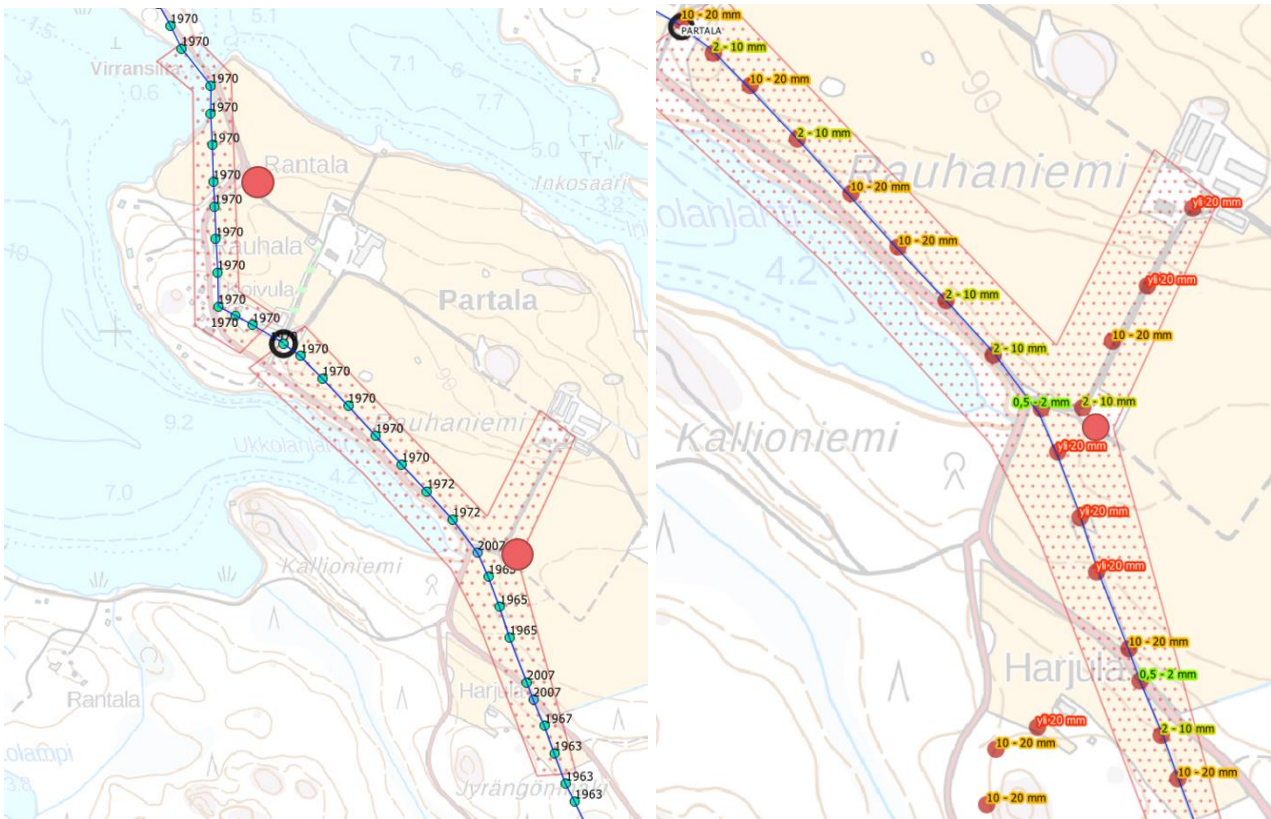
$$I = \frac{R_{1300nm} - R_{1050nm}}{R_{1300nm} + R_{1050nm}}$$

Tämän indeksin laskennassa käytettävien kanavien täsmällisillä aallonpituudet ei pitäisi olla suurata merkitystä indeksin toimivuuteen. Indeksit olisivat mitattavissa dronesta esim. Specim AFX17 kameralla tai käsin esim. Spectral Engines Nirone (S1.4) mittalaitteella.

CCB-kyllästettyjen pylväiden osalta ei saatu riittävästi huonoja näytteitä lahovaurioista, jotta johtopäätöksiä olisi voitu tehdä.


9.1.2 Kuvaukset maastossa

Ensimmäisellä sekä toisella dronelentokampanjalla käytiin pylväisiin painottuen läpi neljä kuvauskohdetta, jotta saataisiin dataa eri-ikäisistä pylväistä (asennusvuodet väliltä 1970-2015). Kuvauksia tehtiin kreosootti-, suola- ja kuparikyllästetyille puupylväille. Osalle pylväistä oli tehty lahotarkastukset. Kuvassa 14 on esitetty Partalan linjaosuus, jossa on vuosina 1965-1970 asennettuja suolapylväitä. Kyseisille pylväille on tehty lahotarkastus vuonna 2019.




KUVA 14. Partalan linjaosuuden pylväiden sijainnit ja asennusvuodet. Oikealla lahotarkastuksen tuloksia. Iso punainen ympyrä kuvaa sijaintia, josta lentojen operointi toteutettiin.

Kuvausdronena käytettiin DJI M600 kopteria johon asennettiin VNIR kuvausta varten Micasense RedEdge-M kamera sekä SWIR kuvausta varten Specim AFX17-kameraa. Jälkimmäisellä kampanjalla kuvauksia suoritettiin myös Senop Rikola HSI kameralla. Kuva 15 esittää esimerkin kolmesta peräkkäisestä kuvasta viidellä RedEdge-M kameran kaistalla. Kaikissa sähkölinja-kuvauksissa kamerat asennettiin kuvaamaan 45° kulmassa etuviistoon ja kuvauslento lennettiin suoraa linjaa yläpuolella kahteen eri lentosuuntaan kuvaten pylväät sekä etu- että takapuolelta.




KUVA 15. Puupylväs kuvattuna RedEdge-M VNIR-kameralla.

CCA-pylväiden kuvauksessa analysoitiin pääasiassa RedEdge-M kameran kuvia. Kuville ei suoritettu orthosuoristusta, mutta kuvien GPS sijaintien perusteella kuvissa esiintyville pylväille tunnistettiin metadatassa esiintyvät pylväiden ID-tunnukset, joiden avulla havainnot voitiin yhdistää esim lahosyvyystietoon. Kuvien värikanavien alignoinnin jälkeen kuvilta poimittiin pylväistä 5 spektriä eri korkeuksilta kuvan 16 mukaisesti.




KUVA 16. Puupylväs kuvattuna RedEdge-M VNIR-kameralla. Siniset täplät merkitsevät kuvasta manuaalisesti poimittujen spektrien näytteistyskohtia.

Pylväiden keskiarvospektreistä laskettiin kappaleessa 7.1.1 esitetyt NDVI-tyyppiset CCA-indeksit ja näitä verrattiin pylväiden mitattuihin lahosyvyyksiin. Lahosyvyyksien ja erityisesti "Red-GreenNIR NDVI"-indeksin välillä havaittiin laboratoriohypoteesin mukaisesti korrelaatio, mutta kaukokartoitusdatassa tämä korrelaatio on niin heikko suhteessa spektrien hajontaan, ettei menetelmä sovellu käytännön kuvauksiin. Menetelmää testattiin myös käyttäen ainoastaan pylväiden alimpia spektrejä, mutta tälläkään näytteistyksestä tulokset eivät parantuneet.




KUVA 17. RedEdge-M kuvalta pylväille lasketut CCA-indeksit vs maastomittausten lahosyvyys.

Koska pylväiden keskiarvoiset maanpäällisten osien spektrit eivät korreloineet riittävästi maanalaisen lahosyvyyden kanssa, koettiin seuraavaksi käyttää indeksejä kuvien filttereinä ja pyrkiä suoraan havaitsemaan pylväissä esiintyviä lahopisteitä. Tällaisessakaan visualisoinnissa kuntotarkastuksessa heikkokuntoiset pylväät eivät erityisesti poikenneet hyväkuntoisista. Joistain ensimmäisen lentopäivän kuvista havaittiin pylväiden juuriosista selkeästi kohonneita indeksien arvoja (Kuva 18), joita päätettiin tutkia toisen kampanjan yhteydessä. Toisen lentokampanjan maastotutkimuksissa paljastui, että nämä kohonneet arvot johtuivat pylväisiin 90-luvulla käytetystä Cobra-lisäkylästeestä, eikä pylväistä löydetty merkittäviä vaurioita. Pylväiden juurilta tällä menetelmällä havaittu signaali ei siis ollut indikaatio lahovaurioista.




KUVA 18. RedEdge-M kuvista lasketut CCA-indeksi-filtteri-kuvat

Seuraavaksi menetelmää testattiin tunnistamalla pylväitä, joissa oli maanpäällisiä lahovaurioita ja kuvaamalla niitä käsivaralla lähietäisyydeltä (Kuva 19). Testissä havaittiin, että vaikka indeksi olivat antaneet laboratoriokokeissa lupaavia tuloksia, kenttäolosuhteiden vaihtelevassa valaistuksessa edes lähikuvasta ei voida tällä menetelmällä erottaa luotettavasti lahovauriokohtia. Vaikka indeksi on itsenormittuva, valaistuksen värerot pylvään eri laidoilla sekä maanpinnasta tulevat virhesignaalit, peittävät lahovauriosta tulevan heikon signaalin sekaansa eikä indeksimenetelmä ole luonnonolosuhteissa käytettävissä. Näitä kuvia koetettiin analysoida myös käyttäen sekä K-Means-clustering että PCA+SAM menetelmiä, mutta kummallakaan menetelmällä, lahovauriokohdista ei saatu irrotettua selkeää tunnistussignaalia.



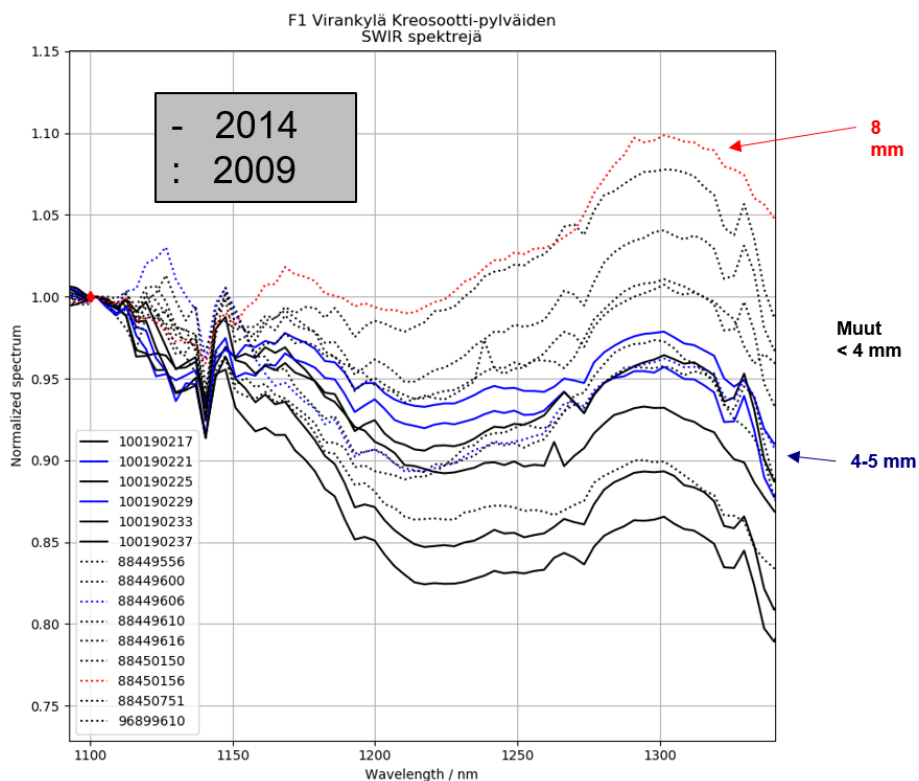
KUVA 19. RedEdge-M kameralla otettu lähikuva CCA pylväästä, jonka juuressa on syvä lahovaurio. Vasemmalla RGB komposiittikuva. Oikealla Red-Green-NIR indeksikuva.

Ensimmäisen lentokampanjan yhteydessä kreosootti-pylväitä SWIR-kuvattiin Specim AFX17-kameralla. Kuva 20 esittää lyhyen pätkän lentolinjan suoristamattomasta AFX17 datasta. Vastaavasti kuten toimittiin myös RedEdge kuvien kanssa, pylväät tunnistettiin kuivilta ja kustakin poimittiin manuaalisesti 5 spektriä eri korkeuksilta (Kuva XX).



KUVA 20. SWIR-kameran ottamaa suoristamatonta kuvaa kreosoottisähkölinjasta. Punaiset täplät merkitsevät kuvasta manuaalisesti poimittujen spektrien näytteistyskohtia.

Lentodatan perusteella vaikuttaisi, että kreosoottisignaalin mukaisesti pylväiden välillä näkyy eroja. Kuvausaineistossa oli yksi pylväs, jolle oli määritetty 8mm lahosyvyys ja kaksi, joilla lahosyvyys oli "4-5mm", kun muiden luokka oli "<4mm". Pylväitä oli sekä vuodelta 2009 että 2014. Kuva X esittää lentodatasta irrotettuja pylväiden spektrejä ja näiden iät ja lahosyvyydet. Huonokuntoisten pylväiden spektrit antoivat aina ikäluokassaan vahvimman kreosoottisignaalin. Kerätyssä lentodatassa lähes kaikki vuoden 2014 pylväät näyttävät indeksissä terveemmiltä vuoden 2009 pylväät. Tämä voi johtua aidosti pylväiden kunnosta, mutta on mahdollista, että kunnan lisäksi esim pylväiden ikä, tuotantosarja tai täsmällinen kyllästysaineen koostumus vaikuttaa havaintoon merkittävästi. Tulokset viittaavat, että menetelmää voisi olla mahdollista käyttää heikoimpien kreosoottipylväiden tunnistamiseen saman ikäluokan pylväiden joukosta, mutta menetelmän laajempaa hyödyntämistä ja tulosten automaattista tulkintaa voi vaikeuttaa signaalin riippuvuus pylväiden iästä ja tuotantosarjasta.



KUVA 21. Kreosoottipylväiden SWIR-spektrejä lahosyvyyden mukaan värjättyinä.

9.2 Jakeluverkon erottimen päävirtatie




KUVA 22. NPS-tyyppin erotin ja palaneet koskettimet.

Jakeluverkon erottimen koskettimien huonokuntoinen välitys voi aiheuttaa erotinvaurioita ja sähkön laatuhäiriöitä laajalla alueella. Jos virtatien kosketin ei ole tarpeeksi kiinni, koskettimet hiljalleen palaavat, hitsaavat ja sulavat. Piiskan näkee maasta, mutta itse päävirtatien kuntoa tai asentoa ei läheskään aina. Jos pää- ja apukosketin ovat huonolla kontaktilla, jossain vaiheessa alkaa tapahtua lämpenemistä ja hitsaamista. Tällöin pinnoilta pitäisi löytyä huonon kontaktin aiheuttaman palamisen jäljiltä ”röpelöä”. Nyt tutkittiin, voisiko koskettimien ympäristöä hyperspektrikameralla kuvaamalla havaita palojälkiä tai muuta materiaalin pinnalle syntyvää muutosta, kun päävirtatien koskettimia on availtu ja laitettu kiinni virrallisena.

Laboratorioon toimitettiin NPS-tyyppin erotin, joka on yleinen erotintyyppi, jota tämän hetken verkosta löytyy. Lisäksi toimitettiin Gevea-tyyppin erotin, joita pääasiassa asennetaan nykypäivänä jakeluverkkoon.

Analyysin jälkeen todettiin, että metallipinnoilla hyperspektrikuvauksesta ei ole suurta hyötyä. Erottimissa näkyy kyllä visuaalisesti selkeitä palojälkiä ja hitsaamia, mutta näistä kerätyistä spektreistä ei löytynyt mitään selkeitä hyperspektrisignaaleja. Palojälkien ja hitsaumien aiheuttamat muutokset ovat pääasiassa vain muutoksia kirkkaudessa, eikä näistä löydetty mitään selkeitä hyperspektrisignaaleja. Tällaiset signaalit sekoittuvat valaistuseroihin ja vastaavan informaation voi saada paremmalla resoluutiolla jo tavallisella RGB-kameralla.

9.3 Muuntajakoneen värimuutoksen luokittelu



KUVA 23. Tutkittuja muuntajakoneita MML:n toimipisteellä Masalassa kuvattuna Rikola hyperspektrikameralla. Vasen: RGB-komposiittikuva. Oikea: NDVI-kasvillisuusindeksikuva.

Tutkittiin, voidaanko hyperspektrillä luokitella muuntajakoneen päältä havaittuja värimuutoksia ja niiden syitä: onko värimuutoksen taustalla öljyvuoto, muu lika, ruoste vai onko värimuutos eläinperäinen. Ruoste muuntajakoneen viereisessä ympäristössä ei pitäisi olla haaste kuvan analysoinnille: kuvasta voidaan luokitella komponentit (tukitangot, muuntajakone, kiristimet yms.) pois. Voidaan myös mm. erottaa muuntajakoneen ulkopuoliset komponentit pois analyysistä. Muuntajan öljyvuoto voi olla hyvinkin muuntajakoneen pohjassa, joten tulisi tarkkailla ja pystyä havaitsemaan myös öljyistä maata muuntajan alla.

Laboratoriossa kerättiin spektrejä erilaisista värimuunnoksista. Laboratoriossa otettiin spektrien lisäksi myös kokonaisesta muuntajakoneesta hyperspektrikuva: laboratorioon vietiin kaksi tyhjennettyä muuntajakonetta ja lisäksi toimitettiin puhdasta sekä käytettyä muuntajaöljyä.

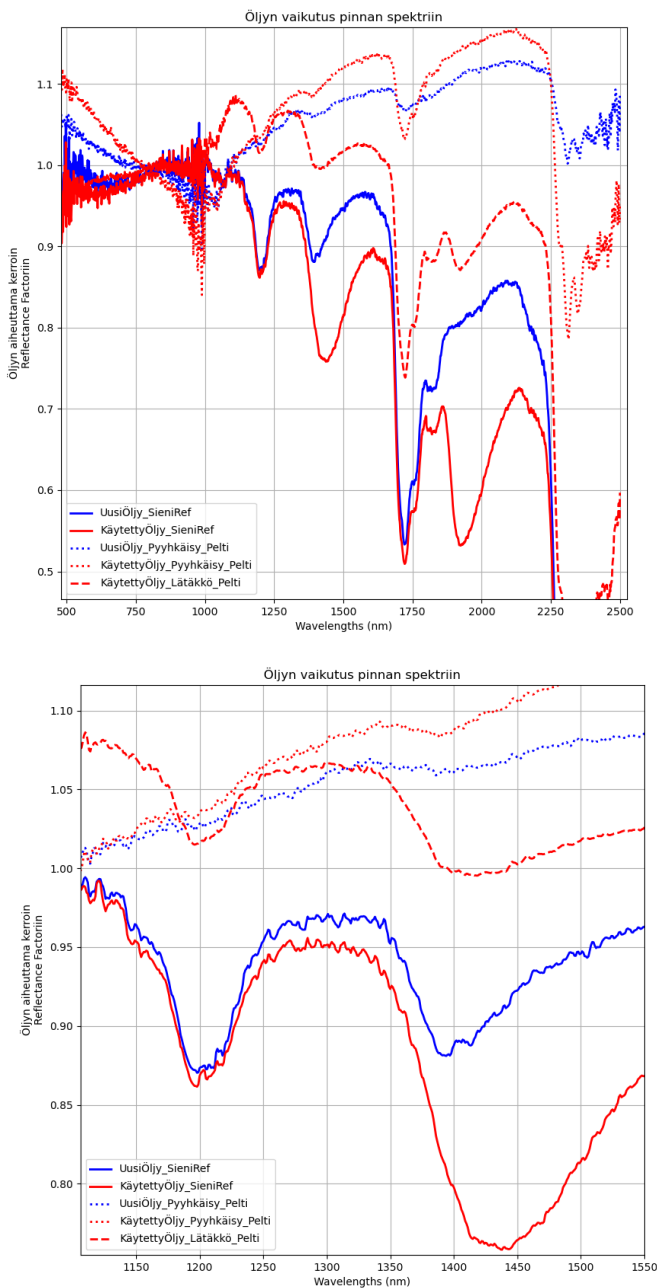
9.3.1 Orgaaniset tahrat

Orgaaniset tahrat antavat VNIR-kuvauksella selkeän red-edge-signaalin, jota voidaan visualisoida esim. NDVI-kasvillisuusindeksin avulla (kuva 23 yllä).

9.3.2 Öljyn havaitseminen

Laboratoriotesteillä pyrittiin tunnistamaan minkälaisia spektraalisia efektejä öljykerros metallipinnalla aiheuttaa. Öljynäytteiden spektrit mitattiin eri pitoisuuksina (Kuva 24). Selkeimmän spektrisignaalin irrottamiseksi musta muovisieni kasteltiin öljystä läpimäräksi ja öljyn spektri suhteessa kuivan sienen spektriin irrotettiin tästä mittauksesta. Sähköverkkojen kaukokartoituksen realistisempaa spektriä varten öljyä mitattiin myös heikompina kerroksina: sekä lätkönä että vain pyyhkäisyä metallipinnalla. Öljyn spektreissä ei ollut VNIR alueella mitään selkeitä signaaleja, joilla sen voisi erottaa muista kohteesta kirkkauseroista tai esim vedestä. SWIR alueella sienen ja lätkön spektreistä on kuitenkin havaittavissa selkeämpiä signaaleja esim 1200nm ja 1400nm kohdilla. Ilmakehän absorptioiden vuoksi näistä ainoastaan 1200nm signaali voisi olla hyödynnettävissä

kaukokartoituksessa, ja öljylätköiden tunnistaminen SWIR spektrometrillä pitäisi olla mahdollista. Pyyhkäisyepitoisuuksissa signaali heikkenee erittäin voimakkaasti eikä todennäköisesti olisi enää luonnonolosuhteissa havaittavissa.




KUVA 24. Käytetyn ja uuden muuntajaöljyn spektrit eri pitoisuuksina. Vasen: koko spektrialue. Oikea: zoomattu näkymä mahdolliseen signaaliin 1200nm kohdalla.

9.3.3 Ruosteen havaitseminen.


Hyperspektrikuvalta erotettiin ruosteen spektrimuoto tutkimalla kuvasta erityisen ruosteista aluetta K-Means ohjaamattomalla luokittelumenetelmällä. Menetelmän tuottamista luokista valittiin

erityisesti ruostetta korostavat luokat ja näiden luokkien keskiarvospektriä käytettiin ruosteentunnistuspektrinä.



KUVA 25. Hyperspektrikuvasta erotettuja spektrimuotoja. Paksu musta viiva on K-means menetelmällä erotettu ruosteen spektri. Muut ovat Principal Component Analysis-menetelmällä (PCA) erotetut kuvan 3 tyypillisintä spektrimuotoa.

Tätä keskiarvospektriä voidaan käyttää kuvien analysointiin Spectral Angle Mapper (SAM) algoritmin avulla. SAM algoritmi vertaa kunkin pikselin spektriä referenssispektriin ja pikselin arvoksi näiden välisen "kulman" joka kuvaa yhdellä numerolla spektrien samankaltaisuutta. Laskemalla kuvan jokaiselle pikselille SAM-kulma suhteessa ruosteen spektriin, voidaan luoda visualisointikuva, joka korostaa kuvassa esiintyviä ruosteisia pikseleitä



KUVA 26: (Vasen) Alignoidusta Rikola hyperspektraalisesta radianssidatakuutiosta erotettu RGB kuva muuntajasta. (Oikea) Ruosteen spektrin muotoja tunnistava SAM kuva

RGB-kameralla on helppo havaita värimuunnoksia. Laboratoriotesteillä haluttiin selvittää, voiko hyperspektri joissain tapauksissa auttaa tunnistamaan värimuunnoksen syy.

Laboratoriotesteissä todettiin öljyn osalta, että SWIR-kuvauksella saadaan signaaleja, joilla lätäkön voi tunnistaa öljyksi. Tätä kevyemmät öljytahrat tuskin antavat riittävän vahvaa signaalia. VNIR-tekniikalla ei signaaleja.

Ruosteen osalta SWIR-tekniikalla ei saatu selkeitä hyperspektrisygnaleja, mutta VNIR-kuvauksella ruosteella vaikuttaisi olevan signaali 800-950 nm kaistalla, jolla sen voisi tunnistaa.

9.4 Eristimien vauriot, hiushalkeamat ja pinnassa oleva kasvusto

Eristimen halkeamat pystytään tunnistamaan ihmissilmin tai RGB-kameralla varsin tehokkaasti. Hiushalkeman tunnistaminen eristimestä hyperspektrillä olisi mielenkiintoinen havainto, koska kyseistä hiushalkeamaa ei näe helikopterista. Pohdittiin, tapahtuuko eristimen pinnassa hiushalkeman johdosta mahdollisesti jokin muutos, joka näkyisi hyperspektrillä. Hiushalkeman kautta vesi pääsee läpi, joka lisää läpilyöntiriskiä. Tästä ei ollut kokemusta, joten asiaa tutkittiin tarkemmin.

Hyperspektri voisi tuoda lisäarvona halkeamien tunnistamiseen halkeaman luotettavamman luokittelun. Lentotarkastuksien yhteydessä linnun jätteitä on luokiteltu halkeamaksi, josta on luotu täysin turha kunnossapitotyö. Hyperspektrikameralla tällaiset virhetulkinnat pystyttäisiin välttämään suurella todennäköisyydellä. Rajoittavimpana tekijänä tässä on nykyisten markkinoilla olevien hyperspektikameroiden pieni resoluutio. Kuvissa 27 ja 28 on tutkittavaksi valittuja eristimiä.




KUVA 27. Tutkittuja eristimiä.



KUVA 28. Tutkittuja eristimiä laboratoriossa.

Laboratoritutkimuksissa eristimistä kerättiin spektrejä ASD FieldSpec 4 spektrometrillä sekä näitä kuvattiin hyperspektrikameroilla. Spektrejä vertaillaessa todettiin, että kaikki posliinit ovat sisältä saman värisiä ja spektraalisesti hyvin samankaltaisia keskenään, kuvan 29 mukaisesti. Näissä on varsin selkeä porrasmäinen spektrimuoto 440 nm spektrikaistan ympärillä. Periaatteessa tämän ympärille luotu spektri-indeksi voisi periaatteessa toimia hyperspektrikameran filttinä tunnistamaan haljenneen paljaan posliinimateriaalin.



KUVA 29. Posliinieristimien eri osien spektrejä.

Tutkimuksissa havaittiin, että vanhimman oloinen, kerman värinen eristin on ulkoiselta spektriltään hyvin samankaltainen kuin sisältä ja indeksi ei toimisi kovin hyvin tässä värityypissä. Havaittiin myös, että erityisesti sinertäväksi värjätty posliinin pinta poikkeaa huomattavasti sisämateriaalin spektristä.

Hyperspektrikuvaus ei kuitenkaan ole todennäköisesti hyvä menetelmä eristimien halkeamien etsimiseksi. Johtuen CCD/CMOS-kamerasensorien tekniikasta, yleisimmät spektrikamerat, ml. Rikola, eivät ole herkkiä vielä 440 nm kaistan alueella, vaan alkavat tuottaa kunnon kuvaa vasta noin 500 nm aallonpituudesta ylöspäin, joten indeksiä ei voisi tuottaa näillä.

Varsinkin hiushalkeamat ovat erittäin pieniä ja hentoja kohteita. Hyperspektrikameroiden pikselikoko on aina suurempi kuin vastaavissa RGB-kameroissa, joten vaikka käytössä olisi erittäin hyväkin filteri, on pienten halkeamien havaitseminen erittäin vaikeaa. 440 nm menetelmä ei toimisi kerman väristen (värjäämättömien) eristimien kanssa ja erityisesti sinertäviksi värjättyissä jo pelkät RGB-kanavat riittänevät vastaavaan tai parempaan erotteluun. Jos pienten halkeamien havainnointia halutaan helpottaa uusissa rakennettavissa sähköverkoissa, voisi olla kannattavaa valita eristiksi värityypiltään sinertäviä tai vielä tummempia eristimiä, jolloin halkeaman värillä on suuri kontrasti pintamateriaaliin.

9.5 Säievika

Aluksi keskusteluissa oli taustalla ajatus, että säieviassa ei suoraan tapahdu materiaalissa muutoksia, joita voitaisiin hyperspektrikameralla havaita. Muun muassa johtimen rautasydämen näkyminen ei todennäköistä, kun johdin alkaa purkautumaan. Johtimissa voi olla palojälkiä vikatilanteiden johdosta, mutta kyseistä havaintoa ei nähty niin merkittäväksi ja sellaiseksi, joka aiheuttaisi verkon toiminnalle erityistä riskiä vikaantumiselle.

Lisäksi alueverkkopuolellakin koettiin, että säievika voi olla hyperspektrille haastava havaintotyyppi: pitäisi pystyä erotella säikeiden purkautumisen johdosta esiin tuleva johtimen sisällä oleva

rautaköysi. Mm. Duck-johtimessa on useampi kerros alumiinijohdinsäikeitä, joten on hyvin epätodennäköistä, että rautaköysi tulisi säikeiden vaurioituessa edes näkyviin, saati että sen näkisi hyperspektrikameralla. Keskusteluissa alkuun päädyttiin siihen, että säievian havaitsemista ei kannatta tutkia hyperspektrikameralla.

Myöhemmin Elveran kanssa käydyssä keskustelussa nousi esiin, että säievika voisi olla kuitenkin kiinnostava. Erityisesti sillä näkökulmalla, että voitaisiinko ennakoida säievikaa analysoimalla palojälkeä, ts. muuttuuko johtimen metallin ominaisuus vikatapahtumassa siten, että sen rakenteen heikentymisen voisi havaita hyperspektrikameralla?



KUVA 30. Johtimen säievika.

Laboratoriotutkimuksissa todettiin, että erottimissa näkyy visuaalisesti hitsaamia, mutta näistä kerätyistä spektreistä ei löytynyt mitään selkeitä hyperspektrisignaaleja. Hitsaumien aiheuttamat muutokset eivät pääasiassa aiheuta muutoksia johtimen kemialliseen koostumukseen, joten ne eivät luo uusia spektrisignaaleja. Myöskin palojäljet ovat spektraalisesti tasaisen mustia ja aiheuttavat johtimeen vain tasaisia muutoksia kirkkaudessa, eikä näistä löydetty mitään selkeitä hyperspektrisignaaleja. Tällaiset signaalit sekoittuvat valaistuseroihin ja vastaavan informaation voi saada paremmalla resoluutiolla jo tavallisella RGB-kameralla.

Periaatteessa ydinvaijeri on eri metallia kuin kuori ja voisi olla spektraalisesti tunnistettavissa. Käytännössä vaijeri on kuitenkin niin ohut ja vaihtelevaa taustaa vasten, että hyperspektrikameroiden nykyisellä resoluutiolla tämä ei ole käytännössä toimiva sovellus.

Näin ollen todettiin, ettei hyperspektrikuvauksesta ole suurta hyötyä metallipinnoilla.

9.6 Kaapelipäätte

Keskusteluissa nousi esiin, että 2012-2013 vuoden kylmäkutisteisissa kaapelipäätteissä oli vetäytymisen kanssa ongelmia. Päätteessä oleva silikoniliukaste aiheuttaa päätteen vetäytymistä. Lisäksi katkaistuissa kaapeleissa päällyskerros (PEX) lähtee vetäytymään. Yhdessä päätteen ja kaapelin eri suuntiin aiheuttama vetäytyminen tuo esiin päätteessä hohtosuojan esiin, jolloin kosteus ja lika pääsevät päätteeseen sisälle, joka puolestaan luo riskin läpilyönnille kosteissa olosuhteissa. Ongelma koskeekin pääasiassa kylmäkutistepylväspäätteitä, ei niinkään sisätiloissa sijaitsevia kaapelipäätteitä: sisätiloissa ei ole juuri kosteutta, joka lisäisi läpilyöntitodennäköisyyttä.




KUVA 31. Laboratoriossa tutkitut kaksi kuumakutistepäätettä.

Kuumakutisteessa ei ole vetäytymisongelmaa, koska päätte liimautuu tiukasti kiinni kaapeliin. Laboratoriossa tutkittiin kuitenkin kahta kuumakutistepäätettä, joissa vikaantumisia on tullut vielä lähivuosinakin. Kyseessä on todennäköisesti ollut asennusvirhe, tai sitten kaapelin päällyskerroksen vetäymä on rikkonut päätteen rakenteita niin, että vika olisi tapahtunut.

Laboratoriossa kuumakutistepäätteistä otettiin spektrit mm. kaapelista, hohtosuojasta ja päätteestä. Hohtosuojan ja kaapelin spektrejä voidaan hyödyntää myös kylmäkutistepäätteongelmien havainnointiin, koska kuvauksessa on kyse metallien tunnistamisesta, eikä niinkään päätteen pinnan ominaisuuksien tarkastelu.

Kaapelipäätteen palojäljistä mitattiin spektrejä ja etsittiin, olisiko niissä mitään tunnistettavia spektrisignaaleja. Mustat palojäljet ovat mustia koko VNIR- ja SWIR-spektrialueella, eikä niitä ole spektraalisesti mahdollista erottaa mustasta muovista tai kumista, kuvan 32 mukaisesti. Laboratoriotesteissä kaapelipäätteistä ei siis löydetty käyttökelpoisia hyperspektrisignaaleja. RGB-kuvat antavat vastaavan informaation kuin hyperspektrikuvaus, mutta paremmalla resoluutiolla.



KUVA 32. Mustien ja palaneiden kohteiden spektrejä laboratorio-oloissa.

9.7 PJ-ylijännitesuoja

Kiinnostavana vikahavaintona esitettiin PJ-ylijännitesuojan rikkoutuminen. Ylijännitesuojia on ennen vanhaan asennettu viimeiselle pylväälle ennen liittymää. Niiden rikkoutumista/laukeamista ei välttämättä näe ihmissilmin. Palojälkiä, nokea tai vastaavaa voi näkyä ulospäin, mutta myös komponentin sisällä on voinut tapahtua mekaaninen rikkoutuminen.



KUVA 33. Rikkoutunut PJ-ylijännitesuoja.

Laboratoriotesteissä todettiin, että musta muovi/kumi on mustaa kaikilla aallonpituuksilla. Palojäljet yms. eivät myöskään anna mitään selkeitä muutoksia spektriin, joten loppupäätelmänä oli, ettei PJ-ylijännitesuojasta saada hyperspektrisignaaleja.

9.8 Puulajien tunnistaminen

Hankkeen tavoitteiden kannalta lehtipuut ja erityisesti pienet lehtipuut ovat mielenkiintoinen tutkimuskohde lumikuormien vuoksi. Lehtipuut voidaan tunnistaa muusta puustosta ottamalla RGB-kameralla kuvat lehdettömään ja lehdelliseen aikaan. Keskenkasvuiset puut kiinnostavat, esimerkiksi latvuksen koon perusteella voisi tehdä analyysia puun koosta. Kuvaus tapahtuu linjatarkastuksessa viistosta, jolloin voidaan saada myös runko kuvattua, joka auttaa lajin tunnistuksessa.


Hyperspektrikamera parantaa puulajiluokittelua ja myös sillä voidaan helposti luokitella havupuut ja lehtipuut sekä tehdä tarkempikin puulajitunnistus. Hankkeessa ei suoritettu koetöitä puulajiluokituksista, koska MML:n tieteellinen tausta aiheesta on jo vahva. Esim. Nevalainen et al. (2017) esittää erityisesti pohjoisiin metsiin testatun dronepohjaisen RGB- ja hyperspektrikuvausmenetelmän ja tutkii, minkälaisia tarkkuuksia on minkälaisia tarkkuuksia puiden tunnistuksissa ja luokitteluissa saadaan perinteisillä menetelmillä. Tästä tehdyssä jatkotutkimuksessa, Nezami et al. (2020) käyttää samaa dataa kuin edellinen, mutta menetelmä on konvoluutioneuroverkko ja tulokset ovat parempia. Molemmissa tutkimuksissa puulajien tunnistuksen menetelmä pohjautuu yhdistelmään RGB-kameran ja FPI-hyperspektrikameran kuvia. Menetelmässä RGB kuvista lasketaan fotogrammetrisesti alueen 3D-malli, josta automaattisesti tunnistetaan sekä maanpinta että puiden latvustot. Tästä 3D pistepilvestä erotetaan yksittäiset puut local maxima-menetelmällä. Kun kukin puu on erotettu, voidaan 3D pilvestä laskea kullekin puu-objektille rakenneparametrejä (esim pistepilven eri persentiilien korkeuksia sekä muotoparametrejä kuten "skewness", "kurtosis", ja "canopy cover"). Vastaavasti hyperspektrikuvista voidaan irrottaa jokaiselle puulle joukko spektrejä, joista voidaan määrittää kohteen keskimääräisen spektrin lisäksi esim mediaania, kirkkaimpia/tummimpia arvoja, sekä eritavoin normitettuja spektrejä. Vuoden 2017 tutkimuksessa puulajiluokitteluun testattiin useita perinteisiä menetelmiä, joista parhaiten suoriutuivat "Multilayer Perceptron" ja "Random Forest" joilla saavutettiin 94.9% ja 95.2% tarkkuudet. Vuoden 2020 tutkimuksessa luokitteluun käytettiin konvoluutioneuroverkkoa, jolla päästiin 98% kokonaistarkkuuteen. Tuominen et al. (2018) tutkimuksessa taas puulajiluokitteluun käytettiin VNIR ja SWIR alueen hyperspektrikameroita. Tässäkin tutkimuksessa perusmenetelmä oli vastaava kuin edellisissä ja kullekin tunnistetulle puulle laskettiin sekä muoto että spektriparametrejä. Luokittelijana käytettiin k-nn luokittelijaa geneettisen algoritmien kanssa. Koska tutkittu metsäalue oli puustoltaan todella monilajinen, tässä tutkimuksessa päästiin vain 82 – 87% tarkkuuteen, mutta tässäkin johtopäätöksenä oli että hyperspektri ja 3D pistepilvet tuottivat yhdistelmänä selkeästi parempia tuloksia kuin kumpikaan erikseen. Yllämainittujen tutkimusten perusteella voidaan todeta, että dronepohjaisilla RGB ja multispektrikameroilla saadaan hyvää tulosta boreaalisissa metsissä, mutta hyperspektrisensorit parantavat tarkkuutta ja ovat erityisen tärkeitä haastavissa luokittelutehtävissä.

10 Tekoälyn hyödyntäminen aineiston jatkokäsittelyssä

Tarkastustoiminnassa luodaan valtava määrä kuva-aineistoa ja mahdollisesti myös muuta dataa, jonka läpi käyminen ihmisvoimin on paitsi erittäin työlästä, myös kallista, ja siten automaattisten tekniikoiden kehittäminen on välttämätöntä. Koska kuntotarkastuksessa valmiin analyysin saaminen ei ole aikakriittistä, voidaan kerätty data purkaa ilma-aluksesta tehtävän päättymisen jälkeen ja analysoida vasta jälkikäteen tehokkailla tietokoneilla. Toinen kohde miehittämättömille ilma-aluksille sähköverkkojen kannalta ovat erilaiset häiriötilanteet, erityisesti suurhäiriöt. Tällaisessa tilanteessa vikapaikkojen nopea löytäminen on ensiarvoisen tärkeää, sillä tällöin korjausresurssit voidaan kohdistaa oikeisiin paikkoihin.

Operatiivisessa sähköverkkojen kuvauksessa tekoälyn ja konenäön käytöllä voidaan vähentää huomattavasti valtavien kuva-aineistojen käsittelyyn tarvittavaa työpanosta. Kuten esim puupylväiden prosessoinnin kuvauksessa on kerrottu, ei sähköverkon kohteiden tutkimiseen ole

yleisesti optimaalista käyttää normaaleja kaukokartoituksen ortomosaikointi prosesseja vaan viistokuvien havainnot tulee pääasiassa tulkita jo suoristamattomilta kuvilta. Hankkeen kokeissa kohteet ja niiden spektrit poimittiin manuaalisesti kultakin suoristetulta kuvalta, mutta tätä työvaihetta voitaisiin tehostaa huomattavasti konenäön avulla. Esim esiovetetty YOLO (You Only Look Once) voidaan suhteellisen helposti siirto-opettaa tunnistamaan RGB kuvilta haluttuja kohteita. MML:n aiemmassa projektissa (Kuva 34) tätä menetelmää sovellettiin mm. autojen tunnistamiseen dronekuvilta. Sama menetelmä on suoraa sovellettavissa esim sähköverkon pylväiden, eristimien, muuntajien, säievikojen ja muiden selkeästi erottuvien verkkokomponenttien automaattiseen paikantamiseen RGB kuvilta. Tunnistuksen kehittämisen suurin haaste on, että kouluttamiseen tarvitaan opetusaineistoa vähintään satoja kuvia halutun tyyppisistä kohteista. Opetusaineisto tulisi kerätä vastaavissa kuvaolosuhteissa ja mahdollisimman vaihtelevissa ympäristöissä kuin mitä varsinaisessa tuotantokuvauksessa tullaan käyttämään.



KUVA 34: Aiemmassa hankkeessa siirtokoulutetulla YOLO-neuroverkolla dronekuvista tunnistettuja autoja MML Masalan toimipisteen ympäristössä

Kohteiden automaattisen tunnistuksen jälkeen kohteiden kunnon tulkintaa voidaan myös automatisoida. Vastaavalla tavalla kuin neuroverkko koulutettiin tunnistamaan RGB kuvilta kohteet, voidaan kouluttaa toinen neuroverkko tunnistamaan irrotetuista RGB kohdekuvista esim. eristimien halkeamia tai muuntajakoneiden värimuutoksia. Koska sähköverkon huollossa on kuitenkin aina myös ihmiset mukana päätöksen teossa, voi olla jo riittävä automaation taso, että nämä konenäöllä tunnistetuista kohteista irrotetaan kuvat, jotka annetaan verkon kuntotutkimuksen asiantuntijalle, joka tulkitsee kuvista lopullisen huoltotarpeen. Jo tässäkin menettelyssä saadaan asiantuntijan työpanosta tehostettua huomattavasti.

Jos automaattiseen tai ohjattuun tulkintaan halutaan hyödyntää hyperspektrikuvausta, kuten aiemmissa kappaleissa on indikoitu, voidaan edellä mainittuja RGB kuvilta tehtyjä kohdetunnistuksia hyödyntää myös tämän prosessin automatisoinnissa. Tällä hetkellä yleisesti saatavilla olevat esikoulutetut neuroverkot eivät osaa suoraa käyttää hyväkseen hyperspektraalisia kanavia tunnistuksessa ja niiden siirtokouluttaminen tämän täysmääräiseen hyödyntämiseen ei ole yhtä yksinkertaista kuin RGB kuvien tapauksessa. Tämän vuoksi kohteiden tunnistuksessa, esim. esikoulutetulla YOLO neuroverkolla, saavutetaan parhaat tulokset todennäköisesti käyttäen korkean resoluution RGB kuvia karkeampien hyperkuvien sijasta. Ideaalilanteessa drone suorittaa kuvauksen synkronoiduilla ja geometrisesti ristiinkalibroituilla RGB- ja hyperspektrikameroilla, jolloin RGB kuvilta tunnistetut kohteet voidaan suoraa osoittaa myös hyperkuvilta. Jos RGB- ja hyperkuvat eivät ole täysin synkronoituja voidaan lähes samasta suunnasta kuvattujen kuvien välille määrittää

keskinäinen alignaatio käyttäen esim. OpenCV ECC-menetelmää (jota on sovellettu tämän raportin liitteenä olevassa Rikola-kuvien alignaatio Python-koodissa) tai lähes mitä tahansa muuta SLAM (*simultaneous localization and mapping*) tai SfM (*structure from motion*) algoritmiä. Hyperkuvien ja tunnistusten yhdistämisen jälkeen voidaan kohteiden tulkintaan käyttää vastaavia luokittelu- ja tulkintamenetelmiä kuin edellisen kappaleen puulajitunnistukselle on kuvattu kuten piirrepohjaisia menetelmiä (esim. päätöspuut), keinotekoisia neuroverkkoja tai syväoppivia konvoluutioneuroverkkoja (CNN). Riippumatta mikä menetelmä lopulliseen sovellukseen valitaan, näiden kouluttamiseen tarvitaan jälleen suuri vähintään sadoista kohteista/kuvista koostuva ja ympäristöltään riittävän vaihteleva koulutusaineisto. Koska linjatarkastustoiminnassa tarkan reflektanssikorjauksen tekeminen on käytännössä mahdotonta, tulisi hyperspektridatan hyödyntämiseksi aineiston myös sisältää kuvauksia vaihtelevissa valaistusolosuhteissa, jotta tunnistus saadaan koulutettua valaistuksesta riippumattomaksi.

11 Yhteenveto

Tässä tutkimuksessa tavoitteena oli selvittää hyperspektrikameran hyödyntämismahdollisuuksia sähköverkon lentotarkastuksilla. Tavoitteena oli selvittää, missä vikahavainnoissa hyperspektrikuvaaminen toisi lisäarvoa tarkastustoimintaan.

Suuri osa sähköverkon tarkastustoiminnan vikahavainnoista karsiutui pois jo asiantuntijakeskusteluiden perusteella. Osasta oli haasteellista saada otettua kuvaa tarkastettavasta kohteesta (esim. eristimen "täyteaineen" rapistuminen, katkennut PAS-linja, kuuran muodostuminen; tämä mahdollista vain maastossa ja vaatii tietyt olosuhteet) tai verkkokomponentin (hyvän ja huonokuntoisen) saaminen laboratorioon kuvattavaksi oli vaikeaa (komposiittieristimet, NAL-erottimet). Joitain havaintoja ei nähty muuten kannattavaksi ottaa tutkimuksen piiriin (alumiiniorren väsyminen, kylmäkutistekaapelipääteen halkeaminen, pylväiden latvahattujen puuttuminen).

Loput kohteista karsiutuivat hyperspektrikuvausten tuloksia tulkitessa: ei löydetty selkeitä hyperspektrisignaaleja. Osasta havaintoja parempaa kuvausmateriaalia saadaan tavallisella RGB-kameralla, erityisesti värimuutosten suhteen. Havaittiin myös, että mustilla kohteilla, kuten musta muovi tai kumi (PJ-ylijännitesuojissa) tai mustat palojäljet (esim. kaapelipääteessä) näkyvät mustina kaikilla aallonpituuksilla eikä niistä saa selkeitä muutoksia spektriin.

Tutkimuksen lopputuloksena todettiin, että hyperspektrikameraa on mahdollista hyödyntää muuntajakoneen värimuutoksen luokittelussa sekä pylväiden kuntotutkimuksessa.

11.1 Muuntajakoneen värimuutoksen luokittelu

RGB-kameralla on helppo havaita värimuunnoksia. Hyperspektrillä voidaan joissain tapauksissa tunnistaa värimuunnoksen syy, onko sen aiheuttajana öljy, ruoste, eläinperäinen lika tai muu lika. Orgaanisilla tahroilla on selkeä red-edge-signaali, joka voidaan tunnistaa esim. multispektraalisella VNIR-kuvauksella. SWIR-kuvauksella öljylätäköön voi tunnistaa öljyksi tietyillä signaaleilla (esim. 1200 nm), mutta testien mukaan lätäköä kevyemmät öljytahrat eivät anna riittävän vahvaa signaalia operatiiviseen toimintaan. Ruoste spektrimuoto voidaan hyperspektraalisista VNIR-kuvauksista käyttäen SAM-spektrivertailumenetelmää.

11.2 Pylväiden kuntotutkimus

Pylvääetä todettiin mielenkiintoisimmaksi ja hyödyllisimmäksi tutkimussuunnaksi. Kenttäkokeissa tutkittiin, korreloivatko hyperspektrikuvausten tulokset linjalle tehdyn lahotarkastuksen millimetreihin.

Järvi-Suomen Energian verkossa kuvattiin eri tavoin kyllästettyjä pylväitä: vanhoja suolakyllästeisiä pylväitä sekä uudempia kreosootti- ja kuparikyllästeisiä pylväitä. Todettiin, että eri kyllästetyyppisten pylväiden kuntotarkastukseen tarvitaan eri spektrialueita.

CCA-pylväiden kuntotutkimukseen löydettiin laboratoriossa signaali 650nm ympäriltä, jota voitiin tutkia korrelaatio punaiseen, vihreään, ja lähi-infrapuna -kanavaan perustuvan kuntoindeksin sekä lahosyvyuden välille. Kenttäkokeissa indeksi ei kuitenkaan toiminut toivotun mukaisesti vaan dronesta kerätyissä spektreissä korrelaatio jää niin heikoksi suhteessa ympäristöstä ja valaistuseroista johtuvaan kohinaan, että tätä ei voida hyödyntää operatiivisessa käytössä. Myöskään suoraa laho kohdista otetuista hyperspektrikuvista lasketuissa indeksikuvissa ei laho kohdat erottuneet valaistus erojen aiheuttamien virheiden seasta. Lupaavista laboratoriotuloksista huolimatta, hankkeessa ei löydetty käyttökelpoista menetelmää CCA pylväiden kuntotutkimukseen.

Kreosoottipylväiden kuntotutkimukseen tunnistettiin laboratoriossa sekä varmistettiin kenttäkokeissa SWIR kuvauksessa erottuva kuntoindeksi 1100-1300nm spektrialueella. Kenttäkokeissa kuntoindeksi erotti huonokuntoisimmat pylväät muista saman ikäluokan pylväistä, mutta lähes kaikki vuoden 2014 pylväät näyttävät indeksissä terveemmiltä vuoden 2009 pylväät. Tämä voi johtua aidosti pylväiden kunnosta, mutta on mahdollista, että kunnan lisäksi esim. pylväiden ikä, tuotantosarja tai täsmällinen kyllästysaineen koostumus voi vaikuttaa havaintoon merkittävästi. Tulokset viittaavat, että menetelmää olisi mahdollista hyödyntää heikoimpien kreosoottipylväiden tunnistamiseen saman ikäluokan pylväiden joukosta, mutta menetelmän laajempaa hyödyntämistä ja tulosten automaattista tulkintaa voi vaikeuttaa signaalin riippuvuus pylväiden iästä ja tuotantosarjasta.

CCB-pylväiden kuntotutkimukseen ei hankkeessa löydetty menetelmiä koska pylvästyyppejä on käytetty vasta niin lyhyen aikaa, ettei huonokuntoisia pylväitä vielä juuri ole eikä täten huonokuntoisia laboratorionäytteitä tai maastokohteita saatu mitattua riittävästi johtopäätöksiä varten. CCB-pylväiden vanhentuuessa tulevana vuosikymmeninä, menetelmän tutkiminen uudestaan on mahdollista.

Yleisesti ottaen pylväiden kuntotutkimuksen tekeminen dronekuvauksella havaittiin haastelliseksi ongelmaksi. Optinen kuvaus mittaa ainoastaan aivan pylvään ulkopintaa ja tyypillisesti puhtaita spektrejä saadaan irrotettua vasta noin 1m korkeudesta ylöspäin. Lahovauriot taas syntyvät pääasiassa pylväiden maanalaisiin osiin, joita optisilla menetelmillä ei voida ikinä havaita suoraa. Mahdollisen havaintomenetelmän pitää siis perustua epäsuoraan havainnointiin eli korrelaatioon maanpäällisen pintaspektrin ja pylvään kunnan välillä. Laboratoriossa tällainen korrelaatio havaittiin sekä CCA- että kreosoottipylväillä, mutta maastokokeissa korrelaatio säilyi vain kreosootteilla. Tutkimuksessa jäi yhä jonkin verran avoimeksi kysymykseksi mistä korrelaatiot varsinaisesti johtuvat. Spektrimuotojen perusteella, varsinkin CCA-indeksin korrelaatio liittyivät todennäköisesti kyllästeaineen spektrivasteeseen, eikä tämä ollut suora havainto puumateriaalin kemiallisesta muutoksesta lahoamisprosessissa. Kreosoottipylväiden signaalista 1100-1300nm alueella ei voi suoraa päätellä onko kyseessä lahoamisesta vai kyllästeestä johtuva signaali, mutta indeksin parempi toiminta kenttäolosuhteissa viittaisi, että tämä voisi olla ainakin osaksi suora lahoamisignaali. Tähän viittaisi myös se, että lähes kaikki vuoden 2009 kreosoottipylväät olivat indeksillä mitattuina huonompikuntoisia kuin vuoden 2014 pylväät. 70-luvun CCA pylväissä vastaava indeksi ei toiminut, joka voi johtua siitä, että käytännössä noin 50v aikana sekä hyvä- että huonokuntoisten pylväiden optisesti mitattava ulkopinta on joka tapauksessa lahonnut eikä pylväiden laatu enää korreloi pinnan kunnan kanssa.

LÄHTEET

ACTi Corporation. 16.11.2016. Conventional vs Thermal Camera. Videotiedosto. Saatavilla:

https://www.youtube.com/watch?v=KHtnf_5dq0U

Aukia, J-P. 2017. Ilmastonmuutos tuo voimistuvia myrskyjä. Erillisverkot. Saatavilla:

<https://www.erillisverkot.fi/ilmastonmuutos-tuo-voimistuvia-myrskyja/>

Baldrige, A.M., Hook, S.J., Grove, C.I., Rivera, G. 2009. The ASTER Spectral Library Version 2.0. Remote Sensing of Environment, vol 113, pp. 711-715. Saatavilla: <https://speclib.jpl.nasa.gov/downloads/2009-Baldrige.pdf>

Boren, H. 2010. Tulevaisuuden sähköpylväs. Loppuraportti. Saatavilla:

https://energia.fi/files/1043/Tulevaisuuden_sahkopylvaat_loppuraportti.pdf

Chen, C., Yang, B., Song, S., Peng, X., Huang, R. 2018. Automatic Clearance Anomaly Detection for Transmission Line Corridors Utilizing UAV-Borne LIDAR Data. Remote Sensing, Volume: 10, Issue: 4, Article Number: 613. Saatavilla:

<https://www.mdpi.com/2072-4292/10/4/613>

Driggers, R., Hodgkin, V., Vollmerhausen, R. 2013. What good is SWIR? Passive day comparison of VIS, NIR, and SWIR. Infrared Imaging Systems: Design, Analysis, Modeling, and Testing XXIV. Saatavilla:

<https://doi.org/10.1117/12.2016467>

Frank, M., Pan, Z., Raber, B., Lenart, C. 2010. Vegetation management of utility corridors using high-resolution hyperspectral imaging and LiDAR. Proc. 2010 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), IEEE, Reykjavik, Iceland, 14–16 June. Saatavilla:

<https://ieeexplore.ieee.org/abstract/document/5594887>

Fritsche, P., Kueppers, S., Briese, G., Wagner, B. Radar and LiDAR Sensorfusion in Low Visibility Environments. DOI: 10.5220/0005960200300036 In Proceedings of the 13th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2016) - Volume 2, pages 30-36. Saatavilla:

https://www.researchgate.net/publication/307879190_Radar_and_LiDAR_Sensorfusion_in_Low_Visibility_Environments

He, T., Zeng, Y., Hu, Z. 2019. Research of Multi-Rotor UAVs Detailed Autonomous Inspection Technology of Transmission Lines Based on Route Planning. IEEE ACCESS, Volume: 7, Pages: 114955-114965. Saatavilla:

<https://ieeexplore.ieee.org/abstract/document/8801830>

Honkavaara, E. ym. 2018. Kvantitatiivista 3D hyperspektristä kaukokartoitusta miehittämättömillä ilma-aluksilla - Teoriasta käytäntöön (QuantitativeRS). Saatavilla: <https://www.maanmittauslaitos.fi/tutkimus/kvantitatiivista-3d-hyperspektrista-kaukokartoitusta-miehittamattomilla-ilma-aluksilla>

Jalil, B., Leone, G.R., Martinelli, M., Moroni, D., Pascali, M.A., Berton, A. 2019. Fault Detection in Power Equipment via an Unmanned Aerial System Using Multi Modal Data. Sensors, Volume: 19, Issue: 13, Article Number: 3014. Saatavilla:

<https://www.mdpi.com/1424-8220/19/13/3014>

Jiang, S., Jiang, W., Huang, W., Yang, L. 2017. UAV-Based Oblique Photogrammetry for Outdoor Data Acquisition and Offsite Visual Inspection of Transmission Line. Remote Sensing. Volume: 9, Issue: 3, Article Number: 278. Saatavilla:

<https://www.mdpi.com/2072-4292/9/3/278>

Jusoff, H. K., Ya'acob, N. 2008. Mapping of power transmission lines on Malaysian highways using UPM-APSB's AISA airborne hyperspectral imaging system. Computer and Information Science.

Kauppa- ja teollisuusministeriön päätös sähköalan töistä 516/1996. Saatavilla: <https://finlex.fi/fi/laki/alkup/1996/19960516>

Kauppa- ja teollisuusministeriön päätös sähköalan töistä annetun kauppa- ja teollisuusministeriön päätöksen muuttamisesta 1194/1999. Saatavilla: <https://www.finlex.fi/fi/laki/alkup/1999/19991194>

Konsulttitoimisto Reneco Oy, Sharper Shape Oy, Next Eagle Oy. 2014b. Lentorobottien pilotointi sähköverkon tarkastuksissa. Saatavilla: https://energia.fi/files/949/Lentorobottien_pilotointi_sahkoverkon_tarkastuksissa.pdf

Konsulttitoimisto Reneco Oy. 2014a. Lentorobotit sähköverkon tarkastuksissa. Saatavilla: https://energia.fi/files/961/Lentorobotit_sahkoverkon_tarkastuksissa.pdf

Konsulttitoimisto Reneco Oy. 2017. Miehittämättömät kauko-ohjattavat ilma-alukset sähköverkoston vianpaikannuksessa. Saatavilla: https://energia.fi/files/1801/Miehittamattomat_kauko-ohjatut_ilma-alukset_verkostovikojen_paikannuksessa_2017.pdf

Laurenzis, M., Christnacher, F. 2013. Laser gated viewing at ISL for vision through smoke, active polarimetry, and 3D imaging in NIR and SWIR wavelength bands. Advanced Optical Technologies, Volume 2, Issue 5-6. Saatavilla: <https://www.degruyter.com/view/j/aot.2013.2.issue-5-6/aot-2013-0040/aot-2013-0040.xml>

Lehtonen, I., Ruosteenoja, K., Mäkelä, A. 2019. Suomen muuttuva ilmasto – tietoa sähkönsiirtojärjestelmän riskien arviointia varten. Ilmatieteen laitos. Raportteja 2019/2. Helsinki. Saatavilla: https://helda.helsinki.fi/bitstream/handle/10138/301521/Suomen_muuttuva_ilmasto_tietoa_s%c3%a4hk%c3%b6nsiirtoj%c3%a4rjestelm%c3%a4n_riskien_arviointia_varten.pdf?sequence=1&isAllowed=y

Matikainen, L., Lehtomäki, M., Ahokas, E., Hyypä, J., Karjalainen, M., Jaakkola, A., Kukko, A., Heinonen, T. 2016. Remote sensing methods for power line corridor surveys. ISPRS Journal of Photogrammetry and Remote Sensing, Volume 119, Pages 10-31. ISSN 0924-2716. Saatavilla: <http://www.sciencedirect.com/science/article/pii/S0924271616300697>

Maxar Technologies. 2014. Revealing the Hidden World with Shortwave Infrared (SWIR) Imagery. Verkkosivusto. Saatavilla: <https://blog.maxar.com/earth-intelligence/2014/revealing-the-hidden-world-with-shortwave-infrared-swir-imagery>

Meerdink, S. K., Hook, S. J., Roberts, D. A., & Abbott, E. A. (2019). The ECOSTRESS spectral library version 1.0. Remote Sensing of Environment, 230(111196), 1–8. Saatavilla: <https://doi.org/10.1016/j.rse.2019.05.015>

Mehaffey, J. 2021. Rain, Snow, Clouds and GPS Reception. Verkkosivusto. Saatavilla: <http://gpsinformation.net/gpsclouds.htm>

Nevalainen, O.; Honkavaara, E.; Tuominen, S.; Viljanen, N.; Hakala, T.; Yu, X.; Hyypä, J.; Saari, H.; Pölönen, I.; Imai, N.N.; Tommaselli, A.M.G. Individual Tree Detection and Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. Remote Sens. 2017, 9, 185. <https://doi.org/10.3390/rs9030185>

Nezami, S.; Khoramshahi, E.; Nevalainen, O.; Pölönen, I.; Honkavaara, E. Tree Species Classification of Drone Hyperspectral and RGB Imagery with Deep Learning Convolutional Neural Networks. Remote Sens. 2020, 12, 1070. <https://doi.org/10.3390/rs12071070>

Niemi, H. Erottimien ja erotinautomaation elinkaaren hallinta. Diplomityö. Tampereen teknillinen yliopisto. Tampere. Saatavissa: <https://www.elenia.fi/files/5fa4f2e3479479524c8a8b761f9229ae61530985/erottimien-ja-erotinautomaation-elinkaaren-hallinta.pdf>

Perić, D., Livada, B., Perić, M., Vujić, S. 2019. Thermal Imager Range: Predictions, Expectations, and Reality. Saatavilla: <https://www.mdpi.com/1424-8220/19/15/3313>

Qiu, Y., Wu, G., Xiao, Z., Guo, Y., Zhang, X., Liu, K. 2019. An Extreme-Learning-Machine-Based Hyperspectral Detection Method of Insulator Pollution Degree. IEEE ACCESS, Volume: 7, Pages: 121156-121164. <https://ieeexplore.ieee.org/document/8815726>

Sähköturvallisuusasetus 498/1996. Saatavilla: <https://www.finlex.fi/fi/laki/alkup/1996/19960498>

Sähköturvallisuuslaki 410/1996. Saatavilla: <https://finlex.fi/fi/laki/alkup/1996/19960410>

Stark, B., McGee, M., Chen, Y. 2015. Short wave infrared (SWIR) imaging systems using small Unmanned Aerial Systems (sUAS). Saatavilla: <https://ieeexplore.ieee.org/abstract/document/7152328>

Stone, M. 2016. A Field Guide to Digital Color. CRC Press.

sUAS.com. 20.12.2018. Can a FLIR Boson Thermal Camera See Through Fog? Videotiedosto. Saatavilla: <https://www.youtube.com/watch?v=Y7mROTPAVZM>

Tuominen, S.; Näsi, R.; Honkavaara, E.; Balazs, A.; Hakala, T.; Viljanen, N.; Pölönen, I.; Saari, H.; Ojanen, H. Assessment of Classifiers and Remote Sensing Features of Hyperspectral Imagery and Stereo-Photogrammetric Point Clouds for Recognition of Tree Species in a Forest Area of High Species Diversity. *Remote Sens.* 2018, 10, 714. <https://doi.org/10.3390/rs10050714>

Verkostosuositus RJ 33:09. Puupylväiden lahoisuustarkistus ja lujjuuden määrittäminen.

Vollmerhausen, R., Driggers, R., Hodgkin, V. 2013. Night illumination in the near- and short-wave infrared spectral bands and the potential for silicon and indium-gallium-arsenide imagers to perform night targeting. Saatavilla: <https://doi.org/10.1117/1.OE.52.4.043202>

Zhang, F., Fan, Y., Cai, T., Liu, W., Hu, Z., Wang, N., Wu, M. 2019. OTL-Classifer: Towards Imaging Processing for Future Unmanned Overhead Transmission Line Maintenance. *Electronics*, Volume: 8, Issue: 11, Article Number: 1270. Saatavilla: <https://www.mdpi.com/2079-9292/8/11/1270>

Zhang, H., Yang, W., Yu, H., Zhang, H., Xia, G-S. 2019. Detecting Power Lines in UAV Images with Convolutional Features and Structured Constraints. *Remote Sensing*, Volume: 11, Issue: 11. Saatavilla: <https://www.mdpi.com/2072-4292/11/11/1342>

Zhang, R., Yang, B., Xiao, W., Liang, F., Liu, Y., & Wang, Z. 2019. Automatic Extraction of High-Voltage Power Transmission Objects from UAV Lidar Point Clouds. *Remote Sensing*, 11(22), 2600. Saatavilla: <https://www.mdpi.com/2072-4292/11/22/2600>

Zhang, Y., Yuan, X., Fang, Y., Chen, S. 2017. UAV Low Altitude Photogrammetry for Power Line Inspection. *ISPRS International Journal of Geo-information*. Volume: 6, Issue: 1, Article Number: 14. Saatavilla: <https://www.mdpi.com/2220-9964/6/1/14>