

Konenäön hyödyntäminen lajien tunnistuksessa ja vesisektorilla

Hanke: Tekoäly ja IoT vesiriskien ja
vesivarojen hallinnassa (ÄlyVesi)

24/02/2020

emblica

Kaisaniemenkatu 1B
00100 Helsinki



1 Johdanto

Älyvesi-projektin tavoitteena on hyödyntää autonomisia ilma-aluksia, konenäköä, IoT –teknologiaa pinta- ja pohjavesiasemilla, ja syväoppimista tulvariskien hallinnassa. Hankkeessa kartoitetaan konenäön avulla kiinnostavia kohteita vesi- ja maaympäristössä seurannan ja biomassan määrän arvioimiseksi sekä arvioidaan jäänlähtöä ja jäätymistä. ÄlyVesi –hanke on osa hallituksen sinisen biotalouden kärkihanketta.

Raportissa on esitetty menetelmiä ja tuloksia tekoälyn soveltamisesta:

- vedenkorkeuden mittaukseen,
- vieraslajien tunnistukseen,
- vesikasvillisuuden tunnistukseen,
- biomassan arviointiin sekä
- jäätymisen ja jäiden lähdön tunnistamiseen.

Maastomittaukset tehtiin kesän ja syksyn 2019 aikana:

- a) ilma-aluksilla (optinen ja spektrikuva): 8 koulutettua kuvaajaa, 4 erilaista ilma-alusta, yli 20 lentopäivää, Suomessa ja Virossa, kartoitettuja alueita noin 100 ha, kuvaresoluutio 1mm – 80 mm (lentokorkeus ~3 -15 m),
- b) kiinteinen kameroin: n. 20 eri paikassa sekä älypuhelimilla,
- c) kenttämittauksina kasvien biomassa arvioita: määritettiin kuvauskohteista satunnaisesti valittuja 1 m² koealoja. Lisäksi yhteistoiminnassa Ruutinlammen kunnostushankkeen kanssa, jossa poistettiin 30 tn vesikasvimaasaa tietyltä vesialueelta, teimme kuvausta ja kuvatulkinntaa sekä ennen että jälkeen vesikasvien poiston
- d) lisäksi otettiin vesinäytteitä sekä mitattiin kenttämittareilla veden laadun ilma-aluskuvatulkintaa varten leväennusteita varten (erillinen raportti) sekä toteutettiin levätulkinnan proof of concept (PoC) 5G verkossa yritys yhteistyössä (tiedote ja video).

Yhteistyössä oli mukana mm. ELY-keskuksia, yhdistyksiä, ProAgraria, Keskkonnaametsten, useita yrittäjiä, sekä oppilaitoksia. Tuloksista on keskusteltu seminaareissa, koulutuksissa, kokouksissa sekä tiedotettu alan lehdissä, internetissä että sosiaalisessa mediassa. Tässä raportissa käsittelemme näiden aliprojektien yhteydessä tehdystä työstä, eli siitä mitä kaikkea olemme kokeilleet, ja mihin lopulta päädyimme. Arvioimme myös ratkaisujen laatua, tulosten vaikuttavuutta ja laajennettavuutta.


2 Vedenkorkeuden mittaus

Vedenkorkeuden havaintoverkko kattaa 600 asemaa ja virtaamaa seurataan 400 pisteessä. Asemilla on sekä automattiset vedenpinnan mittalaitteet, että manuaalisesti havainnoitavat vedenkorkeusasteikot tai muut vastaavat mittausjärjestelyt. Automaattisten mittalaitteiden toimintaa valvotaan sekä etänä, että paikan päällä kuukausittain tehtävillä kontrollikäynneillä, joilla päästään vertaamaan automaatti- ja manuaalimittauksella saatuja vedenkorkeuslukemia. Tämän projektin tarkoituksena on ollut kartoittaa mahdollisuuksia tehdä vedenpinnan manuaalihavainto etänä valokuvista. Tämä mahdollistaisi harvennetun huoltovälin asemille.

2.1 Menetelmät

Suunniteltu järjestelmä perustuu mittausasemille asennettuihin riistakameroihin, jotka kuvaavat mitta-asteikkoa tunnin välein valoisan aikaan (kts. kuva 2a), ja lähettävät sen pilvipalveluun.

Tämän jälkeen toinen järjestelmä hakee kuvat pilvestä, ja muodostaa arvion vedenkorkeudesta. Arviointijärjestelmä koostuu kahdesta Mask-RCNN segmentointiin erikoistuvasta neuroverkosta [5], sekä tätä kaikkea hallinnoivasta ohjelmistosta.



(a) Alkuperäinen

(b) Tunnistuksen jälkeen

Kuva 1: Neuroverkkojen näkemät fidusiaalit, mitta-asteikko ja ennuste korkeudelle.

Ensimmäinen neuroverkko tulkitsee asemalle vietyjen fidusiaalien sijainnit kuvasta (fidusiaalit nähtävissä kolmena puna-valkoisena merkinä mitta-asteikon vasemmalla puolella kuvissa 2a ja 2b). Fidusiaalit on asennettu tiedetyille korkeuksille mitta-asteikkoon nähden, ja niitä käytetään arvioimaan vedenkorkeutta senttimetreissä. Tähän ratkaisuun päädyttiin, koska asemien mittasauvojen numerot olivat useilla asemilla lukukelvottomia, ja koska niihin ei oltu merkitty metrien määriä, ainoastaan senttimetreit; tämän takia mittasauvoja olisi pitänyt muokata jollain tapaa joka ehdolla.

Toinen neuroverkko etsii kuvasta mitta-asteikon sijainnin (kuvassa 2b keltaisella maalattu alue), jonka avulla arvioimme sen, missä veden pinta on.


Lopuksi järjestelmämme arvioi vedenkorkeuden seuraavasti:

1. Arvioi fidusiaalien ylä-, keski- ja alalaitojen pikselisijainnit 1. neuroverkon avulla
2. Arvioi vedenpinnan sijainti pikseleissä 2. neuroverkon avulla
3. Muodosta regressiokäyrä *4PL*-regressiolla [7], ja arvioi tästä jokaiselle pikselille sitä vastaava suhteellinen korkeus
4. Koska tiedämme fidusiaalien korkeudet senttimetreissä, voimme muuntaa näiden pikseliarvot senttimetriksi, ja löytää regressiokäyrältä vastaava senttimetriarvo vedenpinnan pikseliarvolla

Molemmat neuroverkot koulutettiin simuloitulla datalla, mikä luotiin algoritmisesti ja kuvanmuokkaustyökaluilla. Harjoituskuvia luotiin yhteensä tuhansia molemmille neuroverkoille.



(a) Esimerkki fidusiaalista




(b) Esimerkki mitta-asteikosta

Kuva 2: Neuroverkkojen harjoituskuvia.

Fidusiaalit Vedenkorkeuden merkkäamiseen kehitimme oman fidusiaali-enkoodauksen (kts. kuva 3), joka koostuu kahdeksasta radiaanista, sekä kohdistustäpästä. Kahdeksalla radiaanilla voimme muodostaa 256 eri fidusiaalia, joita käytämme merkitsemään **keskimmäisen fidusiaalin** korkeutta seuraavasti:

- Ylin fidusiaali merkitsee keskimmäisen fidusiaalin korkeuden metrien määrää
- Keskimmäinen fidusiaali merkitsee sen fidusiaalin senttimetrien määrää
- Alin fidusiaali toimii tarkistussummana (Luhnin modulo 10:llä), jolla varmistamme että luimme muut fidusiaalit oikein



Kuva 3: Fidusiaali kahdeksalla radiaanilla ja kohdistustäpäällä.

Fidusiaalien enkoodauksen lukua kuvista varten järjestelmämme toimii seuraavasti:

1. neuroverkko palauttaa löydettyjen fidusiaalien sijainnit kamerakuvasta. Käytämme tätä leikkaamaan vain fidusiaalin kuvasta

2. Käännämme kuvaa kohdistustäpän mukaan siten, että jokainen fidusiaalikuva on kohdistettu samansuuntaisesti
3. Muodostamme koodinauhan fidusiaalin sisäympyrästä, josta luemme kahdeksanbittisen koodin (musta edustaa nollaa, valkoinen yhtä)
4. Muunnamme kahdeksanbittisen koodin numeroksi

Tällä järjestelmällä saamme kolmen fidusiaalin pikseli-sijainnin kuvassa, sekä niiden enkoodaaman numeron.

2.2 Tulokset

Tarvittavat kalusteet, fidusiaalit ja riistakamerat, on asennettu vuoden 2019 aikana kolmelle asemalle. Järjestelmämme tunnisti mitta-asteikon luotettavasti kahdella asemalla (kts. kuvat 4a ja 4b). Valitettavasti kolmannen aseman kuvanlaatu oli aluksi liian heikko tunnistukseen (vedenpinnan tunnistus oli hankalaa ihmisisilminkin, kuten on nähtävissä kuvasta 4c. Myös muutamia kuvankäsittely menetelmiä kokeiltiin kuvan laadun parantamiseksi. Myöhemmin kuvausjärjetelyä kolmannella asemalla muutettiin, mutta kyseiset kuvat eivät enää ehtineet mukaan projektiin).



(a) Savijoki.



(b) Rakkolanjoki.



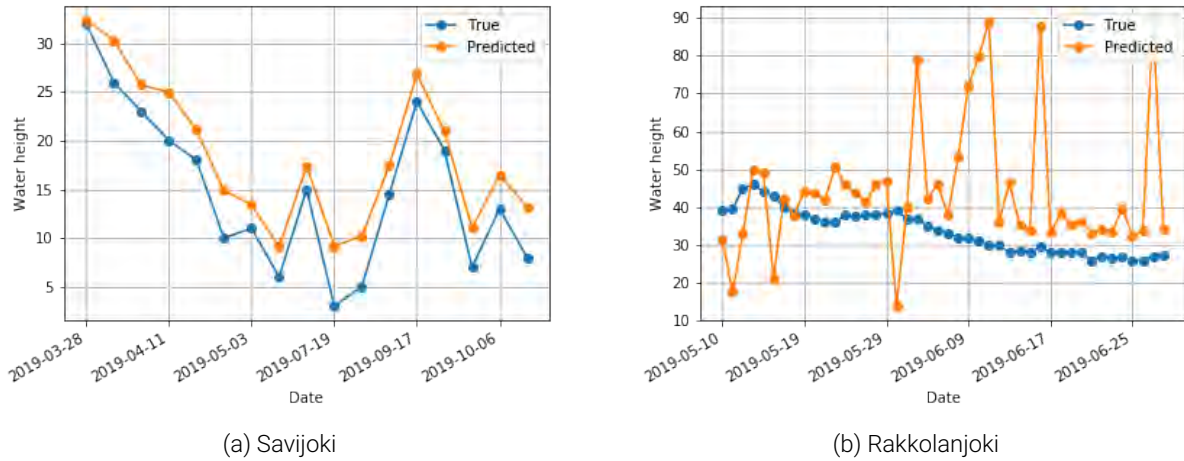
(c) Koskenkylänjoki.

Kuva 4: Kuvat eri asemilta.

Testasimme järjestelmän tarkkuutta kahden hyvinnäkyvän aseman kuvista. Valitsimme yhden kuvan väliltä 6:00-8:00 aamulla jokaiselta päivältä kun kuvia oli saatavilla. Tulokset ovat nähtävissä kuvissa 5a ja 5b.

Tuloksista näemme, että ennusteet ovat olleet keskimääräisesti muutaman senttimetrin päässä oikeasta arvosta.

Selkeitä ongelma-tapauksia on voitu tarkastella kvalitatiivisesti, ja kaksi virhetapausta on havaittu: Ensinnäkin, veden alle on tietyissä valaistustilanteissa näkynyt riittävän hyvin sille, että neuroverkko on nähnyt syvemmälle kuin yleensä. Toisekseen, vaikka koko mitta-asteikko on ollut näkyvässä, on verkko kyennyt tunnistamaan asteikon vain osan matkasta. Näihin ongelmiin ehdotamme ratkaisuja seuraavassa kappaleessa.



Kuva 5: Vedenkorkeuden tunnistus kahdella asemalla.

2.3 Ratkaistuja ja ratkaisemattomia ongelmia

Projektin aikana kokeilimme useita eri menetelmiä ongelman ratkaisemiseksi. MaskRCNN-verkkoihin päädyimme hyvin pian projektin alussa. Ennen niitä kokeilimme YOLO-mallia [8], joka ei ollut riittävän hyvä tarkoituksiimme.

Myös fidusiaaleihin päädyimme hyvin nopeasti, sillä asemien mittasauvoja oli liian vaikea lukea sellaisinaan.

Demossa emme käyttäneet fidusiaalien enkoodausta, sillä emme olleet vielä kehittäneet tätä järjestelmää, kun asemille vietiin ensimmäiset fidusiaalit. Myös algoritmissa joka tulkitsee fidusiaalin koodia on vielä hiomista, sillä tällä hetkellä se ei esimerkiksi havaitse matalakontrastisia kuvia.

Aluksi arvioimme korkeutta lineaarisesti projisoimalla lisää fidusiaaleja vedenpinnan alle. Tästä menetelmästä luovuttiin vasta viime metreillä, sillä kameran linssin kuperuus aiheutti epälineaarista vääristymää kuvissa. Nykyinen 4PL-regressio toimii jo paremmin, mutta kuten voi nähdä kuvasta 5a, on järjestelmässä vielä pientä systemaattista virhettä regression takia.

Kuvasta 5b näkee sen sijaan neuroverkon puutteellisuudet: kun ennuste on selkeästi alempana kuin todellinen arvo, oli kuvissa nähtävissä mitta-asteikon ala-osa / peilikuva vedenpinnalta. Tämä ilmiö oli läsnä vain osan aikaa päivästä, joten ongelmaa voidaan korjata useamman otannon mediaanilla.

Kun ennuste oli todellisuutta selkeästi korkeampi, oli kyseessä aito ongelma neuroverkon koulutuksessa: kuvista oli nähtävissä kuinka neuroverkko ei tunnistanut mitta-asteikkoa kokonaisuudessaan, vaan vain noin puolet. Tämän ongelman ratkaisemiseksi neuroverkkoa voidaan kouluttaa lisää asemakohtaisella datalla, tai joudumme arvioimaan aseman erikoispiirteitä ja kouluttaa verkkoa uudella simuloidulla datalla.

Ensimmäinen vaikutelma on, että ongelmia aiheuttaneella asemalla ongelma oli se, että mitta-asteikko oli liian suuri kuvassa, eikä meidän simulaatioissa ollut yhtään tämän kokoista esimerkkiä verkolle. Ongelmaa voidaan ratkaista myös muuten, kuten ottamalla otantojen mediaanin, tai siirtämällä/kalibroimalla kameraa asennusvaiheessa, kunnes neuroverkko tunnistaa mitta-asteikon parhaiten. Haluaisimme silti ratkaista ongelman ensisijaisesti neuroverkkoa kouluttamalla, ja asemakohtaista dataa saamme koko ajan, joten se on nopeinta tehdä sen avulla.

3 Vieraslajien tunnistus

Vieraslajien tunnistuksessa toteutimme järjestelmän, joka tunnistaa vieraslajeja dronen avulla otettujen kuvista, ja luo niistä raportin kasvien torjuntaa varten. Projektin toteutettiin yhteistyössä BVdrone Oy:n [1] kanssa.

Projektin on tarkoitus selvittää, voidaanko vieraslajeja tunnistaa laajoista luontoalueista kerralla ilman, että maastoon tarvitsee jalkautua niitä etsimään. Tämän järjestelmän avulla voidaan säästää merkittäviä määriä aikaa vieraslajien torjunnan kanssa.

Tunnistettavia lajeja listalla ovat: jättiputki, jättipalsami, japanintatar, kultapiisku, kanadanpiisku, lupiini ja kurturuusu.

3.1 Menetelmät




Kuva 6: Kuva dronesta käsin.

Projektiin valittiin tietoisesti edullinen massamarkkinadrone, koska nähtiin, että kallis dronekalusto voisi olla skaalautumisen este. Massamarkkinadroneiden RGB kamerat ovat jo varsin kehittyneet, joten lähtökohtaisesti valinta on perusteltavissa. Mm. Suomen Poliisi ja Pelastuslaitos ovat myös valinneet edullisia massamarkkinadroneja käyttöönsä, niiden hyvän hinta-laatusuhteen, ja riittävän suorituskyvyn takia. Projektiin valittiin DJI Phantom 4 Pro v2 multikopteri, jonka lentoaika on noin 25 minuuttia, ja 20 Megapikselin (Mpx) kamera on varustettu ns. "global shutter" toiminnolla, jolla varmistetaan että yksittäiset kuvat ovat mahdollisimman tarkkoja. Projektin alkuvaiheessa tehtiin useita testikuvauslentoja dronella ja Syken asiantuntijoilla, jotta löydettäisiin hyvä kompromissi vaaditun tarkkuuden (pikselitarkkuus tai GSD, eli Ground Sampling Distance) ja mahdollisimman ison lentokorkeuden välillä. Lentokorkeus vaikuttaa suoraan pikselitarkkuuteen, mutta kuvaavan alueen suhteen toiseen potenssiin. Esimerkiksi 50 m lentokorkeudesta kuvataan nelikertainen pinta-ala samassa ajassa kuin 25 m lentokorkeudesta. Alussa kokeiltiin sekä pystykuvia että viistokuvia noin 20 astetta pystyakselista sivulle. Testeissä osoittautui haastavaksi löytää kovin tehokas yhdistelmä tarkkuutta ja pinta-alaa. Phantom dronen kamerassa ei ollut optista zoomia, joten varsin laajakulmaisen kameran suurimmaksi mahdolliseksi lentokorkeudeksi, mistä ihminen vielä tunnistaa eri kasvilajit valikoitui noin 16 metriksi. Päätettiin käyttää vain pystykuvia. Siinä korkeudessa drone joutuu lentämään varsin hitaasti – noin 2 m/s, jotta kamera ehtii kirjoittaa kuvat muistikortille. Tämä entisestään vähensi maksimaalisen kuvattavan pinta-alan yhden lennon aikana noin 1,5 hehtaariin. Niin lähellä lennettäessä vaikuttaa myös maaston korkeuserot erittäin merkittävästi lopputulokseen, ja lentoja ei

voida suorittaa kovin korkean puuston alueilla. BVdrone kokeili myös multispektrikuvien ottamista kiinteäsiipisestä dronesta. Kiinteäsiipinen drone piti lentää 60-80 metrin korkeudessa ja multispektrikameran pikselikoko on silloin 4-6 cm/px, jolloin aineistoa ei alkututkimusten jälkeen käytetty konenäkötoeteutuksessa.

BVdrone suoritti automatisoituja kuvauslentoja, kuvaten maata kohtisuoraan alaspäin. Drone ottaa esiohjelmoitua reittiä pitkin sarjassa yksittäiskuvia noin 70-80% päällekkäisyydellä. Jokaiseen yksittäiseen kuvaan on tallennettu metatietona kuvan ottopaikan GPS-koordinaatti jota myöhemmin käytetään kun koneoppimismallin tuloksia yhdistetään takaisin karttatasoksi. Esimerkki näkyvässä kuvassa 6.

Näistä yksittäisistä kuvista pilkotaan ensimmäisenä vaiheena 256x256 pikselin kokoisia osakuvia (Kuva 7). Osakuvat luokitellaan mallin avulla haluttuihin luokkiin. Tässä luvussa esitetty järjestelmä keskittyy nimenomaan



Kuva 7: Yksittäinen kuva pilkotaan osakuviin joista jokainen tulkitaan mallin avulla ja lopuksi tulkinat yhdistetään.

jättiputken tunnistamiseen. Järjestelmä pohjautuu ResNet -neuroverkkoon [6], joka on yksi johtavista luokitteluverkkoista kuville.

Samoin kuin Mask-RCNN:än kanssa, tämäkin järjestelmä tarvitsee pikselitason esimerkkejä siitä, missä tunnistettava luokka (jättiputki) esiintyy opetuskuviissa.

Tämän avulla järjestelmämme toimii itsenäisesti kaikille lajeille, mille opetusaineisto on ollut tarpeeksi kattava. Tällä hetkellä esimerkiksi jättiputkelle olemme saaneet 110 kuvaa, ja tämän koulutusmateriaalin perusteella järjestelmä kykenee tunnistamaan jättiputkia 93% validaatiotarkkuudella (kts. kuva 13). Validaatiotarkkuus kuvastaa koulutuksen aikana käytetyn erillisen validaatioasetin kanssa testattua tarkkuutta, joita ei käytetä mallin koulutukseen.

Datan keräämisestä Keräsimme datalle tarvittavat oikeat vastaukset eksperttien avulla. Tätä varten loimme annotointityökalun (kuva 8), jonka avulla ekspertit annoitoivat kuvista löytyvät vieraslajit. Tästä datasta kasvatettiin augmentoinnilla (kuva 9) kattavampi kokonaisuus esimerkiksi kuvien rotaatioilla sekä värien muunnoksilla.

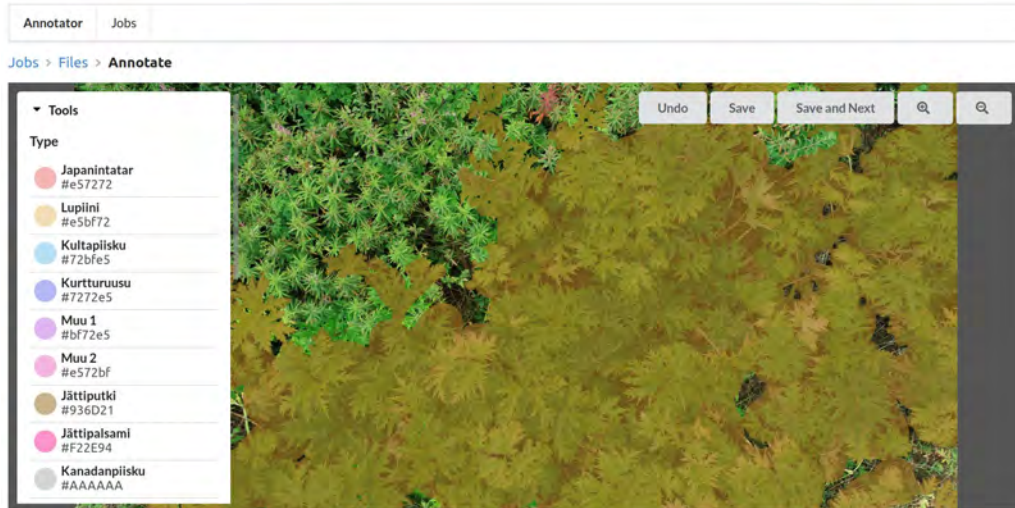
Kuvauspaikkoja oli mm. Oulu, Hollola, Onkivesi, Ruutinlampi, ja Viron puolella Kastell ja Kunda. Kuvia tuli yhteensä 1925, joista annotoitiin 438. Annotoituja kasveja oli pääasiallisesti jättiputket ja jättipalsamit, mutta joukossa oli myös muutamia vesikasveja, kuten ulpukoita.

Lentoasetuksista Riittävät drone-lennätysten asetukset tämänhetkisen tasoiselle tunnistukselle:

- GSD (Ground Sampling Distance) noin 0,4 cm
- Kuvien limittäisyys pituussuunnassa ja leveysuunnassa: vähintään 70% kumpikin

Ominaisuudet Phantom 4 Pro V2.0 kameralla

- 20 Mpx kamera global-shutter ominaisuudella
- Polttoväli 8,6mm (ilmoitettu 8,8mm, mutta tuo 8,6mm lienee todellisuutta)



Kuva 8: Annotointityökalu millä ekspertit voivat merkitä vieraslajit opetuskuviin.

- Sensorikennon leveys: 12,7mm
- Sensorin pikseleitä leveyssuunnassa: 5472
- Sensorin pikseleitä korkeussuunnassa: 3648
- Pystyy ottamaan still-kuvan enintään noin 2s välein
- Hyödynnämme JPG -formaattia

Lentoparametrit:

- Lentokorkeus tällä asetelmalla 16m maan pinnasta, mieluiten maaston korkeuseroja myötäillen. Tämä tuottaa riittävän hyvän kuvaustarkkuuden
- Valotusaika 1/1000 (pimeinä, tasaisen pilvisinä päivinä voidaan käyttää 1/500) vaihtuvalla aukolla (fixed time, changing aperture)
- Nadir, eli kamera osoittaa suoraan alaspäin
- Kuvattavia alueita ajetaan yhdensuuntaisesti – ei tarvitse ristikkäin ajaa
- Ajetaan tuulen nähden mieluiten sivutuulella, jolloin tuulinopeus ei vaikuta lentonopeuteen.
- Parhaan tuloksen saa, jos kuvaa tasaisen harmaana päivänä. Varottava aurinkoheijastumia kuvissa

Mikäli kameran tarkkuus paranee, voidaan korkeutta nostaa, ja samalla vähentää lentoaikoja (kts. kuva 10). Tämä onkin suosituksemme mahdollisille jatkoprojekteille. Hieman kehittyneimmissä dronejärjestelmissä on jo 42Mpx kameroita, ja joissain on mahdollisuus vaihtuvalla optiikalle, jolloin lentokorkeutta voidaan nostaa yli 30 metriä, joka olennaisesti parantaisi lentoturvallisuutta.

Kuvia ei kannata ortostitchata tälle järjestelmälle. Tarkistakaa, että saatte selvää lajeista omalla silmällä.



Kuva 9: Annotointityökalu millä ekspertit voivat merkitä vieraslajit opetuskuviin.

Lentojen tarkastelu Loimme palvelun, millä voi seurata lentojen kattavuutta ja lajien esiintyvyyttä olemassa olevien karttapalvelujen päälle (kuva 11).

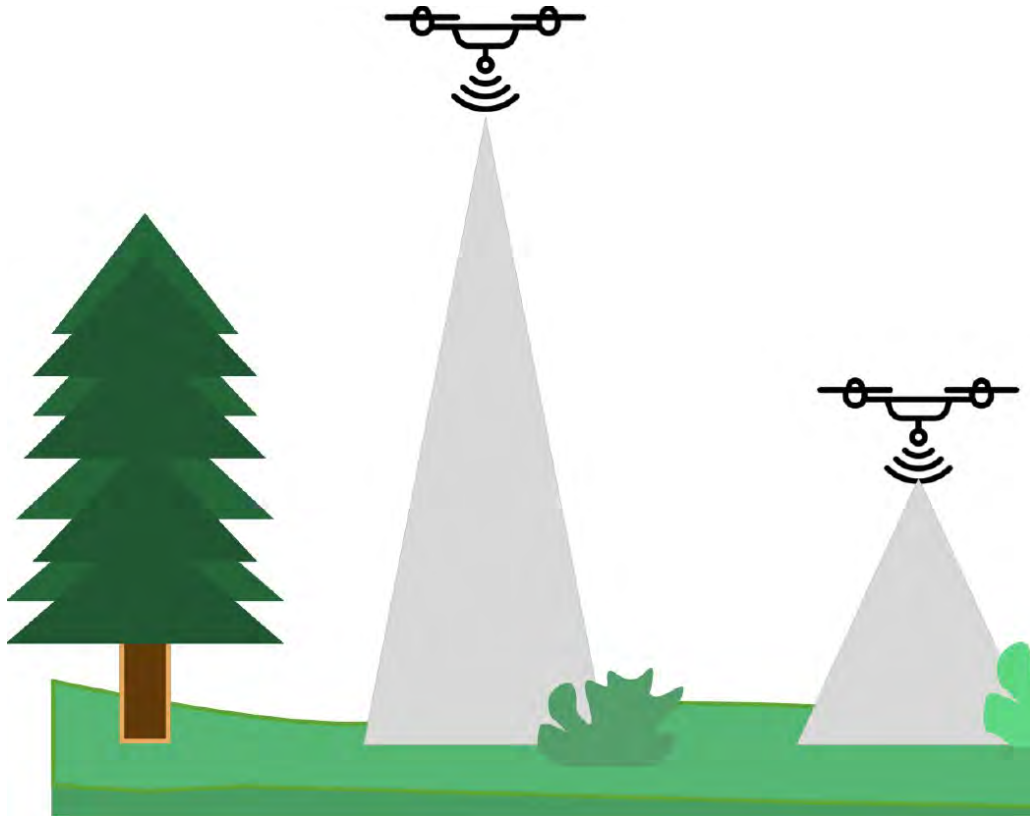
Palvelulla voidaan myös kohdistautua yksittäisiin kuviin, ja saada niistä suoraan järjestelmän ennuste vieraslajeille (kuva 12).

3.2 Tulokset

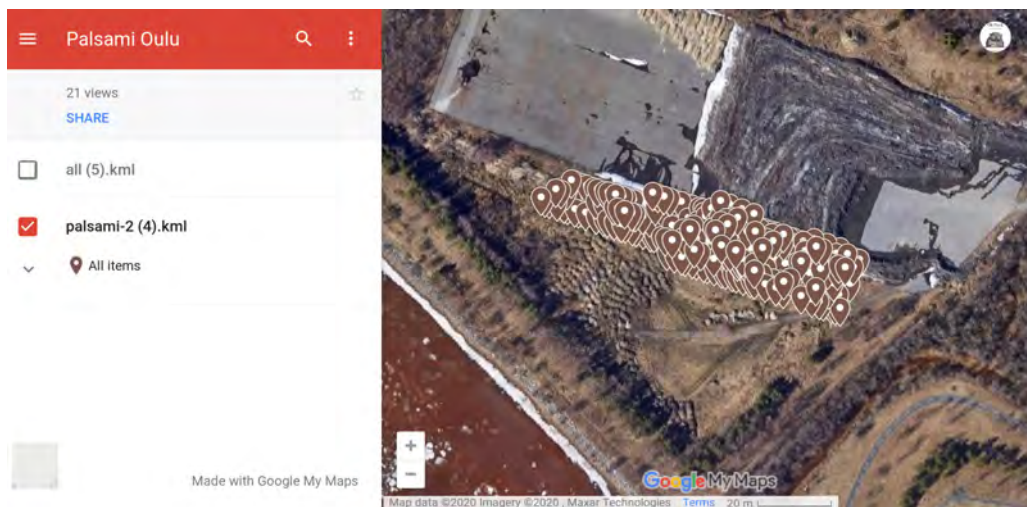
93% tarkkuutta voidaan parantaa kun annotoituja kuvia tulee lisää (erityisen ongelman aiheuttivat nuoret jättiputket, sillä varhaisyyksyllä otetut kuvat sisälsivät vain vanhoja jättiputkia). Vastaava annotointi tulee aikanaan muillekin vieraslajeille, jolloin yhdellä ylilennolla voimme tunnistaa ne kaikki torjuntaa varten. Järjestelmän lopputuotteena voimme sisällyttää vieraslajien sijainnit erilaisiin karttapalveluihin.

Järjestelmä voi tuottaa esimerkiksi hyvin selkeitä luokituksia, värjäämällä jokaisen osion sen luokitustodennäköisyydellä (kuva 14).


Vaihtoehtoisesti luokituksen voi visualisoida lämpökarttana (kuva 15).



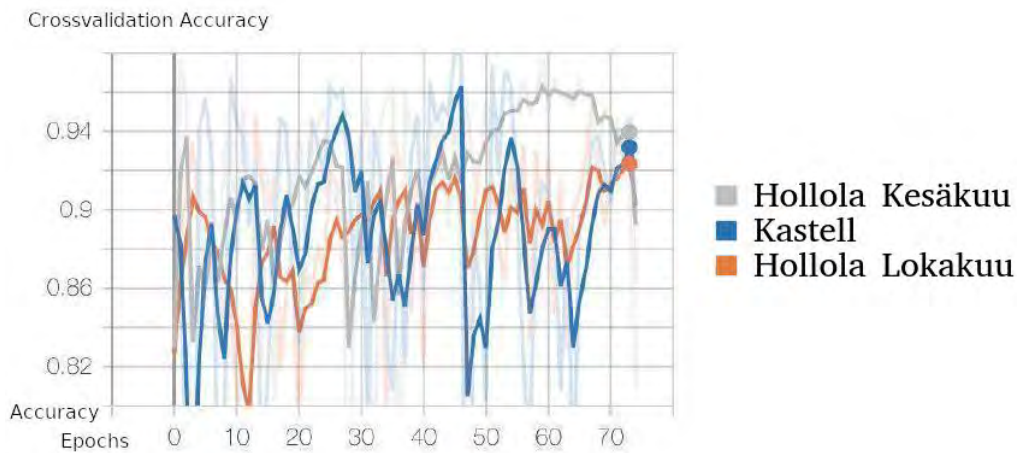
Kuva 10: Lentokorkeuden muutos nopeuttaa kuvausprosessia.



Kuva 11: Karttapalvelu havaintojen hakuun.



Kuva 12: Karttatyökalu havaintojen hakuun.



Kuva 13: Vieraslajien ristivalidaatio kolmelle aineistolle, keskiarvo 93%.


3.3 Ratkaistuja ja ratkaisemattomia ongelmia

Kokeilimme tunnistuksen ratkaisuun useampia menetelmiä, perinteisestä segmentoinnista (U-Net [9]) useampaan luokittelumenetelmään (Inception [11] sekä perinteinen CNN [4]). Päädyimme lopulta edellä mainittuun ResNetiin, sillä se ylsi ylivoimaisesti parhaimpiin tuloksiin silloisella datalla.

Lopullisen järjestelmän varmennukseen käytettiin ristivalidaatiota, missä kolmea kuva-aineistoa vaihdettiin opetuksen ja validaation jaottelussa suhteella kaksi ja yksi (eli jokainen kuva-aineisto oli kerran validointiaineistona, kun opetus tapahtui kahdella muulla aineistolla).

Ongelmakohtia olivat esimerkiksi puute kuvista jättiputkien nuoruusvaiheista, minkä vuoksi järjestelmä tunnistaa tällä hetkellä vain vanhat jättiputket.

Samoin lentokorkeudeksi valitsimme 16 metrin korkeuden, joka on epäkäytännöllinen sekä puiden kannalta, että pienemmän otantavälin kannalta. Korkeammilla kuvasetäisyyksillä ongelman aiheuttaa kuvan huono resoluutio, mistä edes ihminen ei voi tunnistaa mikä kasvi on kyseessä. Tätä voidaan korjata lähivuosina kehittyneemmällä drone-kamerayhdistelmällä.



Kuva 14: Onnistuneita jättiputken luokituksia.

3.3.1 Ortomosaiikin käsittely

Kokeilimme projektin alkuvaiheessa rakentaa ilmakuvista automaattisesti georeferoidun ortorektifoidun mosaiikin. Projektiin BVdrone valitsi testien jälkeen PIX4D ohjelmisto. Operaattorin meille tuottamissa kuvissa oli kuitenkin runsaasti vääristymiä (havainnollistus kuvassa 16) johtuen menetelmästä jotka vaikuttivat merkittävästi tunnistustarkkuuteen, joten luovuimme tästä menetelmästä. Lisäksi on fotogrammetrinen ortorektifointi laskennallisesti hyvin intensiivinen työvaihe, jolloin yhden päivän aikana kerättyjen tuhansien kuvien prosessoimiseen menee helposti useampi päivä.

Tämän seurauksena lopulta projektissa käytetyssä menetelmässä voidaan tulosmosaiikit (maskit) georeferoida samalla yksittäisellä koordinaattipisteellä kuin alkuperäinen yksittäiskuva, mutta jokaiselle pikselille ei saada vastaavaa koordinaattipistettä ja siten kokonaiskuvaan saattaa syntyä tilastollisia ongelmakohteita.

Projektin loppupuolella ongelmaan kehitettiin kuitenkin ratkaisu, jota ei valitettavasti ole toistaiseksi päästy kokeilemaan tuotannossa. Menetelmässä malli ajetaan alkuperäisille kuville jolloin vääristymiä ei synny, ortorektifioimalla lasketaan kuitenkin käänteismuunnokset jokaiselle tulokuvulle ja näiden käänteismuunnoksien avulla rakennetaan lopullinen karttataso. Täten vääristymiä syntyy ainoastaan lopulliseen karttatasoon jolloin vääristymät aiheuttavat vähemmän ongelmia kuin mallin syötteeseen. Tämä työtapo ilman ortorektifointia tiputtaa myös kuva-aineiston vaadittava käsittelyaika päivistä minuutteihin. Kun vielä huomioi että ortorektifointi edellyttää noin 70-80% limittäisyys vierekkäisten kuvien kesken, mutta viimeisin kehitetty menetelmä toimii paljon




Kuva 15: Onnistuneita jättiputken luokituksia.



Kuva 16: Havainnollistus automaattisesti tuotetun mosaiikin vääristymistä

pienemmällä limittäisyydellä on helppo ymmärtää, että kuvatta alue yhden lennon aikana kasvaa 1,5 ha:sta use-

aan hehtaariin.



Kuva 17: Mosaiikki rakennetaan alkuperäisistä kuvista affini muunnoksilla. Käänteismuunnoksien avulla voidaan yksittäisten kuvien pohjalta lasketuista maskeista muodostaa georeferoitu karttataso

Oulusta opittua Oulusta opimme useamman asian kuvausten käytäntöön liittyen:

Valaistus vaikuttaa suuresti lajien tunnistettavuuteen.

Kuvakulma vaikuttaa tuloksiin (kuvan tarkkuus kärsii objektiivin reunoilla olevilla alueilla ja myös muu tunnistustarkkuus heikkenee).

Lentokorkeus vaikuttaa valaistusolosuhteiden, sään ja kamerasäätöihin. Sopivaa korkeutta joudutaan joskus tilanteesta riippuen vaihtamaan.

Visuaaliset representaatiot näistä ilmiöistä nähdään kuvassa 18.


4 Vesikasvillisuuden tunnistus

Vesistöjen kasvillisuuden tunnistukseen käytimme U-Net neuroverkkoa [9], joka muodostaa pikselitason luokituksen kuvalle. Vesistökasvillisuudesta on annotoitu jo ulpukoita, joille koulutimme tämän verkon.

Ajan puitteissa kerkesimme toteuttamaan vain yhden testin. Mutta vaikka tuloksia on niukalti, ne ovat erinomaisia, mikä antaa viitteitä menetelmän kannattavuudesta.

4.1 Menetelmät

Myös vesikasveja voidaan tunnistaa dronekuvista. Vesikasvien kanssa dronen lentokorkeus voi olla matalampi, sillä puita tai pensaita ei ole esteenä. Tämä mahdollistaa myös pienempien kohteiden havaitsemisen, tai tarkastelun pintaa syvemältä. Ongelmaksi yhä jää se, että lentoaika pitenee, ja käsiteltävän datan määrä kasvaa.




Kuva 18: Kuvausolosuhteiden muutokset vaikuttavat tunnistukseen.

Alkuvaiheen testeissä todettiin, ettei 16m lentokorkeudesta vielä luotettavasti erota eri vesikasvit toisistaan käytetyllä kalustolla. Todettiin, että viiden (5) metrin lentokorkeus tuottaa halutun tarkkuuden, eli 1mm/px. Dronen törmäksenestojärjestelmät pitää kytkeä pois kun lennetään niin lähellä veden pintaa, ja lentonopeus laskee noin 1m/s, jolloin on mahdollista enää kuvata on 0,1 – 0,2 ha alue yhden 25 minuutin lennon aikana. Dronekuvaus tehdyllä tavalla on siten varsin tehoton menetelmä kokonaisten järvien vesikasvillisuuden tunnistamiseksi. Pistokokeiden toimittamiseen drone taas soveltuu erittäin hyvin.

Valitsemallemme U-Netille voidaan syöttää dronekuvat kokonaisina (kts. kuvat 20a,20c), minkä perusteella se luo luokituksen jokaiselle pikselille (kuvat 20b,20d).

4.2 Tulokset

Alustava tulos U-Netin koulutuksesta näkyy kuvassa 19: treenikäyrä (sininen) on yhä nousujohteinen, vaikkakin hyvin pienellä välillä. Samoin validaatiokäyrä pysyy hyvin pienellä välillä lähellä treenikäyrää (huomaa oikeassa



Kuva 19: U-Netin tarkkuus ulpukoille.

laidassa näkyvät arvot).

Lopullinen validaatiotarkkuus on 97.6%.

Tämä yksin ei vielä riitä vakuuttamaan neuroverkon toimivuudesta, mutta on lupaava alku. Sen sijaan kuvakokeelmassa 20 näkyy, kuinka se on toiminut esimerkkikuville: Valkoista taustaa vasten näkyvät siniset varjot ovat järjestelmän havaitsemat ulpukat. Tästä on mahdollista toteuttaa järjestelmä, joka esimerkiksi laskee arvion lehtien määrästä täyttämällä varjot sopivalla menetelmällä. Jatkotesteistä havaitsimme kuitenkin, että järjestelmä kykenee tämän tasoiseen tunnistukseen vain samankaltaisissa kuvaolosuhteissa: se ei kyennyt tunnistamaan lumpeita kuvasta, missä lumpeet olivat pelkästään limittäin (rehevyyssaste lähes 100 %).


4.3 Ratkaistuja ja ratkaisemattomia ongelmia

Järjestelmän ratkaisuun oli jo kokeiltu samoja menetelmiä kuin vieraslajienkin tunnistukseen. Päivitimme kuitenkin menetelmän U-netiin, sillä tällä menetelmällä biomassan estimoinnista tuli luotettavampi, ja nämä kaksi projektia kulkevat käsi kädessä saman ympäristön vuoksi.

Ratkaisemattomana ongelmana on vielä se, kuinka varjot tunnistetaan yksittäisiksi laskentaa varten. Erilaiset menetelmät varjojen täyttöön esimerkiksi saattavat täyttää myös lehtien väliset aukot. Tämä sama ongelma tulee eteen myös biomassan estimoinnissa, mikä kuvataan seuraavassa osiossa.

5 Biomassan estimointi

Biomassan estimoinnilla [10] voidaan arvioida jonkin pinta-alan kasvillisuusindeksiä. Estimointi voidaan toteuttaa suoraan, kuten kasvien painon laskentaa, tai epäsuoraan, kuten kasvien peittävyden mittausta (kts. kuva 21). Kasvillisuusindeksillä voidaan tarkastella esimerkiksi metsien ja järvien tilaa, kuten rehevyyttä tai kasvillisuuden monimuotoisuutta.




(a) Alkuperäinen



(b) Ennuste



(c) Alkuperäinen



(d) Ennuste


Kuva 20: U-Netin ennuste ulpukoille.



Kuva 21: Biomassaa estimoidaan epäsuorasti.

Alustavien arvioiden mukaan kuitenkin edellä mainittuja dronekuvia on mahdollista käyttää myös biomassan estimointiin.

Yksi esimerkki implisiittisestä estimointijärjestelmästä on kuvassa 22. Ennusteesta voidaan laskea lajikkeiden



(a) Ennuste

(b) Estimaatti

Kuva 22: Esimerkki vesistön biomassan estimoinnista. Tunnistuksen perusteella voidaan laskea tunnistetun luokan pinta-ala kuvasta, mistä saadaan suoraan lajin suhteellinen pinta-ala luonnossa.

muodostama pinta-ala, mikä antaa suoraan halutun biomassan määrän.

Paras järjestelmä tähän olisi yllä kuvattu U-Netiin pohjautuva järjestelmä, jolla voidaan laskea jokaiselle pikselille sen luokitus (onko se esimerkiksi ulpukka vai ei).

Yllä kuvattua järjestelmää ei voida ottaa suoraan käyttöön tähän tarkoitukseen vielä, vaan se vaatii ainakin yhden tukijärjestelmän toimiakseen. Ongelmana on dronekuvien päällekkäisyys: samaa kasvia kuvataan useasti eri kulmista, jolloin niiden laskenta vaikeutuu. Tähän on ratkaisuna ortomosaiikin luonti, mikä liittää kaikki kuvat yhteen. Valitettavasti tämä tuottaa artefakteja kuvien rajoille, jolloin biomassan tarkka estimointi häiriintyy suhteessa otettujen kuvien lukumäärään.

6 Jäätymisen ja jäiden lähdön tunnistus

Projektin tarkoitus oli tutkia jäätymisen ja jäiden lähdön arviointi automaattisesti käyttäen rannoille asennettuja kameroita. Maastokuvaukset tehtiin 14.4.2019 Espoossa, joissa simuloitiin jäänlähtöä ja jäiden liikettä (kts. Kuva 23). Projektille toteutimme alustavan arvion, sillä pääpaino oli muissa osa-alueissa.




Kuva 23: Jään liikkeen kuvaus Espoo Leppävaarassa 14.4.2019, liikettä simuloitu heittämällä jäätä ojaan.

Tälle projektille toteutimme vain alustavan arvion, sillä keskityimme enemmän pääprojektin muihin osa-alueisiin.

Kokeilimme AutoML järjestelmää [2] kolmansilta osapuolilta kerätyllä kuvamateriaalilla. Koska emme saaneet kameroita maastoon ajoissa kuvaamaan vesistöjä, keräsimme noin 9000 kuvan aineiston kolmansilta osapuolilta.

Valitettavasti nopeasti kerätty materiaali ei ollut tarpeeksi laadukasta hyvien tuloksien saavuttamiseksi.



Kuva 24: Jäidenlähdon luokkien visualisointi.

Kuten näemme kuvasta 24, järjestelmä pystyi jakamaan luokitukset (jäätynyt, sula, puolijäässä) tyydyttävällä tasolla. Valitettavasti puolijäätynyt oli vaikea erotella kahdesta muusta luotettavasti (punaiset pisteet).

Alustavan arvion mukaan järjestelmä on kuitenkin mahdollista toteuttaa, sillä vastaavantyyllisiä ratkaisuja on jo olemassa [3]. Erityisesti jos saamme useamman riistakameran esimerkiksi vedenmittausasemien läheisyyteen. Kolme kameraa asennettiin jo kesän aikana, joista voimme nyt tulevana kuukausina saada materiaalia jäätymisestä.

7 Yhteenveto

Seuraavassa yhteenveto konenäön soveltuvuudesta viiteen eri tehtävään:

- Jäätyminen ja jäiden lähdön luokittelu onnistui asemille asennettujen kameroiden kuvista käyttäen AutoML-menetelmä. Ennen palvelun käyttöönottoa on tuotettava laadukas ja laaja opetusaineisto menetelmän soveltamiseksi eri vesistöalueilla, sen jälkeen menetelmä on laajennettavissa.
- Vedenkorkeusasemalle sijoitettiin kameroita sekä koneluettavia korkeusmerkkejä vedenkorkeusasteikon vedenkorkeuden tulkitsemiseksi paikasta riippumatta. Opetusaineistoa oli rajoitetusti, joten virtuaalimalleja hyödynnettiin opetusaineiston tuottamisessa. Kuvat tulkittiin käyttäen kahta Mask-RCNN segmentointiin erikoistuvaa neuroverkkoa sekä kuvan oikaisuun käytettiin lineaarista regressioyhtälöä. Vedenkorkeus voitiin tulkita noin 5 cm tarkkuudella. Asemakäyntien määrään voidaan vaikuttaa kameroita lisäämällä. Laajennettavuutta rajoittaa hyvien kamerapaikkoja määrä.
- Vieraslajien tunnistamiseksi laajemmilta alueilta paras tulos saatiin ResNet – neuroverkolla (Residual neural network). Opetettavia lajeja oli paljon ja opetusaineiston tuottamisen kustannus on suuri, joten opetusaineistoa kyettiin tuottamaan riittävästi vain jättipalsamista ja jättiputkesta. Tuhansia kohteita merkittiin kuviin ja tunnistuksen luotettavuus oli 90-95 % opetusaineistolla, lentokorkeuden ollessa noin 15 m. Tunnistukseen luotettavuus vaihteli merkittävästi koulutettujen ilma-aluskuvaajien välillä Oulun koealueella. Menetelmää voidaan laajentaa, mutta opetusaineiston määrä tulee lisätä merkittävästi, jotta voidaan kattaa riittävästi erilaisia kuvasolosuhteita ja paikkoja. Menetelmän laajennettavuuteen liittyvä haaste on lentokorkeus, jonka tulisi olla yli 25 m, jotta toiminta olisi helposti laajennettavissa. Liiketoimintapotentiaali on globaalisti merkittävä.
- Vesikasvit, vesikasvien tunnistaminen onnistui hyvin U-Net neuroverkolla, lentokorkeuden ollessa 3-5 m, kuvaresoluutio 1 mm. Kuvista tunnistettiin hyvin kelluslehtisistä ulpukka ja uistinviita. Opetusaineistoa ei ollut riittävästi ennakkoon valittujen 10 lajin tunnistamiseksi. Hyvä kuvaresoluutio kohteen tunnistamiseksi on noin 1/10 kasvin koosta. Ilma-aluksen lennättämisessä huomiota on kiinnitettävä lentonopeuteen, valaistusolosuhteisiin sekä varmuuteen lentokorkeudesta. Menetelmän on laajennettavissa ja sovellettavissa, kun saadaan tuotettua riittävä ja laadukas opetusaineisto.
- Biomassa arvioitiin tunnistetuille vesikasveille tunnistettujen lehtien peittävyuden avulla, mutta lehtien kapalemäärän laskeminen vaatii jatkokehittämistä. Lajit tunnistettiin U-Net neuroverkolla. Päällekkäisten ja limittäisten lehtien tunnistaminen onnistui vain osin ja oli erittäin haastavaa ylirehevässä Ruutinlammessa.
- Leväbiomassa: Ilma-alus kuvista tulkittiin Porvoossa klorofylli biomassa sekä sameus arvo, joiden luotettavuus määritettiin, mikä mahdollistaa tiedon yhdistämisen muuhun tietoon, kuten satelliittikuviin. Yritysyhteistyössä, 5G verkossa, tehty kokeilu reaaliaikaisesta kuvatulkinnasta mahdollistaa esim. kalankasvattamoiden vaikutusten seurannan reaaliaikaisesti. Menetelmän laajennettavuutta vedenlaatuotteiden osalta paikallisen kalibroinnin tarve sekä kuvatulkinnan osalta opetusaineistojen saatavuus.

Kaikissa projekteissa opetusaineiston laatuun ja määrään on kiinnitettävä erityistä huomiota, jotta menetelmä on sovellettavissa useampaan erilaiseen käyttötapaukseen. Kuvatunnistuksessa tehokas tapa on tunnistaa kohteet alkuperäisistä kuvista, jolloin vääristymiä ei synny, ja vasta sen jälkeen muodostaa lopullinen karttataso tunnistetuista kohteista, näin karttatason vääristymät aiheuttavat vähemmän ongelmia kuvatunnistusprosessissa.

References

- [1] Bvdrone oy. <https://www.bvdrone.com>.
- [2] Google automl. <https://cloud.google.com/automl/>.
- [3] Scene classification. <https://paperswithcode.com/task/scene-classification/codeless>.
- [4] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. The MIT Press, 2016.
- [5] K. He, G. Gkioxari, P. Dollár, and R. Girshick. Mask r-cnn, 2017.
- [6] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition, 2015.
- [7] M. O’Connell, B. A. Belanger, and P. D. Haaland. Calibration and assay development using the four-parameter logistic model. 1993.
- [8] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi. You only look once: Unified, real-time object detection. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788, June 2016.
- [9] O. Ronneberger, P. Fischer, and T. Brox. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015.
- [10] T. Silva, M. Costa, and J. Melack. Assessment of two biomass estimation methods for aquatic vegetation growing on the amazon floodplain. *Aquatic Botany*, 92:161–167, 04 2010.
- [11] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich. Going deeper with convolutions. In *Computer Vision and Pattern Recognition (CVPR)*, 2015.

Appendices

A Dronelennot

Toteutuneet dronelennot vuonna 2019. Toteuttajana BVdrone Oy, paitsi Oulun kuvat (** merkittynä) toteutettu neljällä paikallisella dronekuvaajalla BVdronen lisäksi. Sarakkeina päivämäärä, sijainti, annotoidut/kuvatut kasvit. Seuraavassa taulussa listataan mallit, sekä mitä kuvia käytettiin niiden koulutukseen, validointiin, ja lopulta mallin tarkkuus.

Vieraslajeja ovat: Jättipalsami, jättiputki, japanitar, lupiini, kurturuusu, kultapiisku ja kanadanpiisku.

Vesikasveja ovat: Ulpukka, uistinviita, ulpukka, kilpukka, kelluskeiholehti, pystykeiholehti, vesitatar, rantapalpakko, siimapalpakko ja järviruoko.

Yhteensä projektin aikana tuotettiin 16 500 RGB kuvaa ja 2 140 multispektrikuvaa

Menetelmä	Pvm	Sijainti	Kasvit	Annotoitu
Optinen	24.3.	Otsolahti, Espoo	Vesikasveja	0/200
Optinen	14.4.	Leppävaara, Espoo	Jäänlähtö	0/200
Optinen	7.6.	Kiiminki, Oulu	Vieraslajeja	0/60
Optinen	24.6.	Pitkäjärvi, Espoo	Vesikasveja	63/1664
Optinen	25.6.	Hollola	Vieraslajeja	31/697
Optinen	26.6.	Viro	Vieraslajeja	0/4493
Optinen	1.7.	Ruutinlampi	Vesikasveja	56/3860
Optinen	26.7.	Ruutinlampi	Vesikasveja	0/2145
Optinen	29.7.-2.8.	Onkivesi	Vesikasveja	104/3190
Optinen, Spektri	2.8.	Keskimmäinen, Kuopio	Vesikasveja	0/?
Optinen	6.8.	Hakijärvi, Maaninka	Vesikasveja	0/?
Optinen	7.8.	Ruutinlampi	Vesikasveja	0/920
Optinen	8.8.	Oulu**	Vieraslajeja	1/596
Optinen	13.8.	Savonjärvi, Lapinlahti	Vesikasvit	0/?
Optinen, Spektri	15.8.	Hollola	Vieraslajeja	110/299
Optinen	26.-27.8.	Viro, Kunda, Kastell	Vieraslajeja	75/75
Optinen	1.9.	Oulu	Vieraslajeja	0/?
Optinen, Spektri	11.9.	Oulu	Vieraslajeja	0/?
Spektri	14.10.	Oulu	Vieraslajeja	0/?
Spektri	28.10.	Porvoo	Vedenlaatu	0/1000

Malli	Koulutuskuvat	Validointikuvat	Tarkkuus
Ulpukan tunnistin	Pitkäjärvi, Ruutinlampi, Onkivesi	Samat	97.6%
Uistinvidan tunnistin	Ruutinlampi, Onkivesi	Samat	??
Jättipalsamin tunnistin	Hollolat	Oulu	??
Jättiputken tunnistin	Hollolat	Viro	93%