



Luonnonvara- ja
biotalouden
tutkimus 19/2019

Esiselvitys 3D-kameratekniikan ja koneoppimisen hyödyntämisestä suomalaisessa kalankasvatuksessa


Matti Janhunen, Jari Niukko, Harri Vehviläinen, Markus Kankainen
Jarmo Hakulinen ja Olavi Pesonen

Luonnonvara- ja biotalouden tutkimus 19/2019

Esiselvitys 3D-kameratekniikan ja koneoppimisen hyödyntämisestä suomalaisessa kalan- kasvatuksessa

Matti Janhunen, Jari Niukko, Harri Vehviläinen, Markus Kankainen,
Jarmo Hakulinen ja Olavi Pesonen

Luonnonvarakeskus, Helsinki 2019



Viittausohje:

Janhunen, M., Niukko J., Vehviläinen, H., Kankainen, M., Hakulinen, J. & Pesonen, O. 2019. Esiselvitys 3D-kameratekniikan ja koneoppimisen hyödyntämisestä suomalaisessa kalankasvatuksessa. Luonnonvara- ja biotalouden tutkimus 19/2019. Luonnonvarakeskus. Helsinki. 24 s.



ISBN 978-952-326-732-9 (Painettu)

ISBN 978-952-326-733-6 (Verkkajulkaisu)

ISSN 2342-7647 (Painettu)

ISSN 2342-7639 (Verkkajulkaisu)

URN <http://urn.fi/URN:ISBN:978-952-326-733-6>

Copyright: Luonnonvarakeskus (Luke)

Kirjoittajat: Matti Janhunen, Jari Niukko, Harri Vehviläinen, Markus Kankainen, Jarmo Hakulinen ja Olavi Pesonen

Julkaisija ja kustantaja: Luonnonvarakeskus (Luke), Helsinki 2019

Julkaisuvuosi: 2019

Kannen kuva:

Painopaikka ja julkaisumyynti: PunaMusta Oy, <http://luke.juvenesprint.fi>

Tiivistelmä

Matti Janhunen¹⁾, Markus Kankainen²⁾, Harri Vehviläinen³⁾ ja Jari Niukko²⁾, Jarmo Hakulinen⁴⁾ ja Olavi Pesonen⁴⁾

¹⁾Luonnonvarakeskus (Luke), Yliopistokatu 6B, 80100 Joensuu

²⁾Luonnonvarakeskus (Luke), Itäinen Pitkäkatu 4 A, 20520 Turku

³⁾Luonnonvarakeskus (Luke), Korkeakoulunkatu 7, 33720 Tampere

⁴⁾MettaVita Oy, Pirjeläntie 8, 20660 Littoinen

Tehokas kalankasvatus edellyttää tarkkaa ajantasaista tietoa kalojen lukumäärästä, aktiivisuudesta, terveydentilasta ja kasvusta (biomassasta). Tämä mahdollistaa erilaisten toimenpiteiden, kuten ruokinnan, lajittelun, kasvatustiheyksien ja lopulta perkuuajankohdan optimaalisen hallinnan. Videovalvonnan ja -ohjauksen käyttö on lisääntynyt merkittävästi kalankasvatuksen seurannassa ja tuotannonohjauksessa.

Myös tietokoneavusteiset kuva- tai videoanalyysit ovat kehittyneet viimeisten kolmen vuosikymmenen aikana, ja ne ovat avainroolissa kasvatettavien kalastojen automaattisessa, ilman ihmistä tapahtuvassa mittaamisessa ja analysoinnissa. Tärkeimmät käytännön sovellukset liittyvät kasvatettavan kalaston ruokinnan ja biomassan seuraamiseen mutta myös kalaterveyteen ja välineiden kunnossapitoon. Kalankasvatusmarkkinoille on kehitetty jonkin aikaa muun muassa 3D-videoseurantaan perustuvia biomassalaskureita, mutta toistaiseksi niiden tarkkuus ei ole ollut välttämättä riittävä. Suomen sameissa rannikkovesissä laskureista ei ole raportoituja käyttökokemuksia, eivätkä sovellukset huomioi kotimaassa kasvatettavia kalalajeja. Laskurit ovat myös verrattain kalliita, jolloin kilpailukykyisten sovellusten kehittäminen voisi lisätä niiden käyttöä ja hyötyjä.

Tähän hankeraporttiin koottiin esiselvitys:

- Tämänhetkisistä seurantasovelluksista kalankasvatuksessa
- Kolmiulotteisen (3D) kuvamateriaalin soveltuvuudesta ja jatkokehitysmahdollisuuksista kasvatettavien kalojen seurannassa kotimaiset erityisolohdevaatimukset ja tekoälyn omat reunaehdot huomioiden.

Kuvauskokeiluissa ruokailevista kaloista (kirjolohi ja siika) saatiin liikedataa, josta pystyttiin toteamaan niiden aktiviteetin muutoksia. Datamäärät jäivät kuitenkin pieneksi varsinaista mallintamista ajatellen. Myös kuhakasvatusta kuvattiin, mutta samean veden ja kuhan passiivisen ruokailukäyttäytymisen takia niiden liikeaktiivisuutta ei havaittu. Kalojen pituudesta saatiin luotettavia metrisiä mittaustuloksia 3D-kameradatan avulla, joskaan näytemäärä ei ollut tässäkään tapauksessa suuri suoraan biomassan arviointiin. Tulosten perusteella 3D-kuvasta saatuja pituusmittoja voitaisiin käyttää kalojen kasvun tarkempaan arviointiin ilman invasiivisia (stressaavia) välimittauksia.

Hanke on toteutettu yritysyritysteistyönä Luken koordinoimassa ja Euroopan meri- ja kalatalousrahaston rahoittamassa vesiviljelyn innovaatio-ohjelmassa vuonna 2018.

Asiasanat: kalankasvatus, 3D-kuvaus, mallinnus, optiset sensorit, seurantateknologia

Sisällys

1. Johdanto	5
2. Kirjallisuuskatsaus	6
2.1. Kalankasvatuksen seurannassa hyödynnettäviä sovelluksia	6
2.1.1. Optiset sovellukset ruokinnanohjauksessa	6
2.1.2. Optiset sovellukset kalojen ja niiden biomassan laskennassa	7
2.1.3. Muita teknisiä sovelluksia ja käyttökohteita	9
2.2. 3D-kameratekniikka	11
2.3. Koneoppiminen.....	13
3. Kalojen liikkeen havainnointi	14
3.1. Käytöksen luokittelu ja seuranta	14
3.2. Tulokset.....	14
3.2.1. Kirjolohi	15
3.2.2. Kuha	16
3.2.3. Siika	16
4. Kalojen koon arviointi.....	18
4.1. Tarve	18
4.2. 3D-mittaukset	18
4.3. Tulokset.....	18
4.3.1. Kuha	19
4.3.2. Siika	19
5. Lisäselvitystarpeet?	20
6. Yhteenveto.....	22

1. Johdanto

Tehokas kalankasvatus edellyttää tarkkaa ajantasaista tietoa kalojen lukumäärästä, aktiivisuudesta, terveydentilasta ja kasvusta (biomassasta). Tämä mahdollistaa erilaisten toimenpiteiden, kuten ruokinnan, lajittelun, kasvatustiheyksien ja lopulta perkuun optimaalisen hallinnan. Tietokoneavusteiset kuva- tai videoanalyysit ovat kehittyneet huomattavasti viimeisten kolmen vuosikymmenen aikana, ja niihin liittyviä sovelluksia kehitetään jatkuvasti kalankasvatuksen seurannassa, automatisoinnissa ja analysoinnissa.

Pääasiassa videoseurantaa hyödynnetään nykyisin kalankasvatuksen ruokinnanohjauksessa ja biomassalaskureissa, vaikka muitakin sovelluksia on käytössä ja kehitteillä. Siten tässä esiselvityksessäkin rajauduttiin arvioimaan sovelluksia, joilla voisi seurata kalojen ruokintakäyttäytymistä tai arvioida kalojen biomassaa. Koska koneoppimisen hyödyntäminen on lisääntynyt tuotannon tehostamisessa ja suunnittelussa, Luonnonvarakeskus (Luke) aloitti esiselvityshankkeen yhteistyössä MettaVita Oy:n kanssa, jolla on kokemusta koneoppimisen sovelluksista sekä alustavasti myös 3D-kameratekniikan hyödyntämisestä. Vaikka markkinoilla on jo 3D-koneoppimissovelluksia ja niihin liittyviä tutkimushankkeita (mm. biomassanarviointiin), todettiin että niiden tarkkuustaso, hinta ja sovellukset Suomessa kasvatettaville kalalajeille antavat mahdollisuuden kehittää sovelluksia erityisesti Suomeen, mutta mahdollisesti myös kansainvälisille markkinoille. Samalla hankkeen tavoitteena oli saada lisätietoa ja videomateriaalia kotimaisten kasvatustilajien käyttäytymisestä.

Tämän raportin kirjallisuuskatsauksessa käydään läpi olemassa olevia teknisiä sovelluksia kalankasvatuksen seurannassa ja tuotannonohjauksessa. Samassa osiossa on myös lyhyt yleiskuvaus koneoppimisesta ja 3D-kameratekniikasta. Myöhemmissä osioissa kerrotaan kokemuksia erilaisilta tuotantokaloilta (kirjolohi, siika ja kuha) kerätystä testiaineistosta. Tämän pohjalta on mahdollista arvioida, voidaanko kolmiulotteisella (3D) videokameratekniikalla koneoppimiseen yhdistettynä löytää sovellusalueita, jolloin kaloja ja niiden käyttäytymistä on mahdollista seurata ja siten kehittää esimerkiksi ruokinnanohjausta automaattisemmaksi. Jatkokehitysmahdollisuuksia pohditaan kotimaiset kalankasvatuksen erityisolosuhtevaatiukset huomioiden. Hanke on toteutettu vuonna 2018 Luken koordinoimassa vesiviljelyn innovaatio-ohjelmassa, johon on saatu rahoitus Euroopan meri- ja kalatalousrahastosta (EMKR).

2. Kirjallisuuskatsaus

Mittaustietoon ja tekniikkaan perustuva tuotannonohjaus on nykyaikaa kalankasvatuksessakin. Tässä osiossa avataan pääpiirteittäin toimialalla tunnettuja teknisiä kalastonseurantaratkaisuja. Pääpaino on kalojen ruokinnanohjaukseen ja biomassan arviointiin sovellettavassa kameratekniikassa, mutta koosteessa esitetään myös muutamia muita menetelmiä, joilla kalastoa voidaan, tarkoituksellisesti riippuen, havainnoida. Samalla tuodaan mukaan tekoälyn käsitteistöä ja pyritään alustavasti selvittämään sovellusten reunaehdot. Erilaisten kasvatustaikavaloilla mitattavien vedenlaatu- tai muiden ympäristöparametrien, kuten lämpötilan, happipitoisuuden, pH:n sekä virtausnopeuksien, seuraamiseen kehitettyjä sensoreita ei kuitenkaan käsitellä tässä yhteydessä (kts. esim.

[https://www.akvagroup.com/pen-based-aquaculture/camera-sensors/enviro-sensors-\).](https://www.akvagroup.com/pen-based-aquaculture/camera-sensors/enviro-sensors-)

2.1. Kalankasvatuksen seurannassa hyödynnettäviä sovelluksia

2.1.1. Optiset sovellukset ruokinnanohjauksessa

Vedenpäälliset tai -alaiset (video-)kamerat ovat tavallisimpia teknisiä apuvälineitä kalastonvalvonnassa ja -seurannassa tämän päivän kalankasvatusasemilla (esim. norjalaisten AKVA Groupin ja Steinsvikin mallistot:

<http://www.akvagroup.com/cage-farming-aquaculture/camera-sensors/camera-systems->,

<https://steinsvik.no/en/products/e/seaculture/camera-systems>, tai australialainen AQ1 Systems:

http://www.aq1systems.com/uploaded/271/13510019_68aqtv_digitalbroc_lores.pdf). Niitä hyödynnetään pääasiassa manuaalisesti tai puolimanuaalisesti kalojen käyttäytymistä tarkkailtaessa ja siten myös ruokinnanohjauksessa (Kankainen 2015). Esim. Norjassa lohien ruokinta perustuu jo miltei yksinomaan ihmisen valvomaan reaaliaikaiseen videokuvaan. Seurantaan perustuvalla ruokinnalla voidaan tehostaa kalojen rehunkäyttöä, ylläpitää niiden hyviä kasvuominaisuuksia sekä reagoida aktiivisesti kalojen hyvinvointiin. Luken kokeiluissa Steinsvikin pinta- ja vedenalaiskameroiden laatu on osoittautunut hyväksi Brandön ja Kustavin alueiden kirkaassa vedessä (Kankainen 2015; Kankainen ym. 2019). Vedenalaiskameralla näkyvyys oli hyvä jopa 20–25 metrissä. Sisäsaariston sameissa vesissä näkyvyys oli sitä vastoin heikko, vain luokkaa 0,4–0,85 m.

Erityyppiset optiset sensorit ja tietokonenäkö tarjoavat kehittyneempää automaattista tarkkailuteknologiaa, joskin niiden soveltaminen kalankasvatukseen on edelleen haastavaa: Tarkkailtavat kalat ovat herkkiä häiriötekijöille (esim. ylimääräisille valonlähteille), helposti stressaantuvia ja vapaita liikkumaan ympäristössä, jossa valaistus, näkyvyys ja stabiliteetti eivät yleensä ole kontrolloitavissa. Lisäksi tarkkailulaitteiden täytyy toimia veden alla tai märissä olosuhteissa. Parhaimmillaan tietokonenäköön liittyvillä menetelmillä voidaan kuitenkin saada täsmällistä tietoa kaloista, mukaan lukien niiden liikkumisaktiiviteetistä, ryhmittymisestä ja käyttäytymisen muutoksista (Mathiassen ym. 2011; Zion 2012; Hao 2016; Saberioon ym. 2017; Niu ym. 2018). Tietokonenäköä hyödynnetään myös rehupellettien tai suurempien pintaloisten (lohitäiden) määrien seuraamisessa. AQ1 Systemsin itseohjautuvan AQ300-ruokintajärjestelmä annostelee rehua kalojen ruokahalun perusteella (http://www.aq1systems.com/uploaded/271/13510010_34aq300broc_lores.pdf). Tämä tietokoneohjattu järjestelmä koostuu ruokkimesta (esim. Arvo-Tec Oy; <http://www.arvotec.fi>), vedenalaisesta keräyssuppilosta ja sen alareunassa olevasta infrapuna-anturista. Lisäksi järjestelmään kuuluvat virtaus-, happi- ja lämpötilamittaristo sekä happidiffuusori. Keräyssuppilon sensori rekisteröi syömättä jääneet rehupelletit, ja tietokone hidastaa tai kiihdyttää rehun syöttöä tämän – siis kalojen ruokahalun – perusteella. Itseohjautuvalla ruokintajärjestelmällä on mahdollista parantaa kalojen rehukerointa (Airaksinen ym. 2003). Adaptiivinen ruokinta-algoritmi säättää ruokintaa osin myös veden virtauksen, happisaturaation ja veden lämpötilan suhteen.

Erlaisia kuva-analyysitekniikoita ja liike-analyysiä on kehitetty ja käytetty joidenkin kalojen ja rapujen käyttäytymisparametrien automaattisessa määrittämisessä, mutta Suomessa kaupallisesti kasvatettaville lajeille sopivat sovellukset puuttuvat vielä (Patullo ym. 2007; Duarte ym. 2009; Pinkiewicz ym. 2011; Niu ym. 2018).

2.1.2. Optiset sovellukset kalojen ja niiden biomassan laskennassa

Kalaparven kokonaisbiomassa sekä kalojen lukumäärä ja kokojakauma ovat lähtökohtana monille kalatuotantoprosessissa tehtäville päätöksille (mm. oikeiden ruokintasuhteiden määrittäminen ja kokonaistuoton arviointi ennen kalojen teurastusta). Luotettavat järjestelmät kalojen lukumäärän ja biomassan kontrolloinnille ovatkin avain kestäväen ja kustannustehokkaan kalankasvatuksen kehittymiselle.

Vielä nykyisinkin tavallisin tapa arvioida kalojen biomassaa tai keskipainoa on otosperusteiset väli-punnitukset. Tämänkaltainen menetelmä on paitsi työläs ja epätarkka, se voi aiheuttaa kaloille ylimääräistä stressiä ja pintavaurioita. Ranskalainen Faivre valmistaa kalanviljelykäyttöön sekä pelkkiä kalalaskureita (esim. Pescavision 300) että monimutkaisempaa videokuvaan perustuvaa laitetta, joka määrittää myös yksilöiden painot (Pescasight 100: 0,2–50 g:n kaloille, luvatus maksiminopeuden ollessa 600 000 kalaa tunnissa (0,5 g); <http://www.faivre.fr/index.php/en/products/fish-counters/19-en-produits/275-fish-counter-transfer>). Molemmat laitteet ovat liitettävissä esim. pumppuun tai kalankuljetusauton purkupuutkeen. Pescasight 100:n laskentaa varten otetaan ensin esim. 30 kalan kokonaispaino, joka syötetään koneelle. Tämän jälkeen kaloja syötetään yksitellen laitteeseen, joka laskee kappaleet ja jokaisen painon. Kalan painon laskenta perustuu siihen, että ohjelma laskee kuvasta, kuinka monta pikseliä kukin yksilö on, ja laskuri tietää alussa tehdyn kalibroinnin perusteella, paljonko yksi pikseli painaa. Mittauksen tarkkuuden arviointia varten laite tuottaa myös videon, josta voi varmentaa, kuinka paljon laskenta tekee virhettä (esim. laite luulee kahta kalaa yhdeksi). Kalojen painoa laskevaa mallia ei ole toistaiseksi tarjolla isoille kaloille. Faivren lisäksi perinteisempiä, vaihtelevalla kokoskaalalla ja nopeudella toimivia kalalaskureita edustaa islantilaisen Pentair Aquatic Ecosystemsin monipuolinen VAKI-mallisto (<https://pentairaes.com/products/stock-control-management/vaki/fish-counting>). Osassa näistä laskureista on lisäoptiona myös kalojen keskipainon määrittäminen (<https://pentairaes.com/vaki-nano-counter.html>, <https://pentairaes.com/vaki-macro-exel-counter.html>). Myös itävaltalaisen AquaTech-yrityksen valikoimissa on kalalaskureita, joista osa sisältää myös kalojen keski- ja yhteispainon sekä painojakauman laskevan kamera-/mittausjärjestelmän (<http://www.aquaculture-com.net/other.htm#Scales>; ”PIPELINE COUNTERS for many fishes”).

Vaihtoehdoksi kalojen fyysisille mittauksille painojakauman/biomassan arvioimiseksi on viimeisen 30 vuoden aikana kehitetty modernia kalaystävällistä teknologiaa (Zion 2012; Hao ym. 2016; Saberioon ym. 2017). Esim. stereokamerajärjestelmissä kaksi kameraa asetetaan rinnakkain, jolloin ne ottavat ja prosessoivat kuvia synkronoidusti ikään kuin kolmiulotteisessa tasossa (van Rooij & Videler 1996; Costa ym. 2006). Kunkin stereoskooppisesti kuvatun kalan paino määritetään sen lateraalisia dimensioita (esim. ruumiinpituutta ja -syvyyttä) ja geometrisia algoritmeja käyttämällä. Esim. Beddow ym. (1996) testasivat digitaalisen stereokameran soveltuvuutta lohen biomassan arviointiin. Lohien biomassan estimointivirhe oli vain alle 4 %:n luokkaa (parhaimmillaan 0,5 %) todellisesta arvosta. Nykyisin stereokameroita valmistavat ainakin AKVA group ja AQ1 Systems (<http://www.akvagroup.com/cage-farming-aquaculture/camera-sensors/camera-systems/biomass-estimator>, http://www.aq1systems.com/uploaded/271/13510020_78am-100broc.pdf). Ensin mainitun yrityksen digitaalisen Vicass HD -kamerayksikön kerrotaan ottavan 300–500 kuvaa kolmesta eri syvyydestä ennen niiden analysointia. Kameraa mainostetaan täsmälliseksi ja tehokkaaksi kalojen keskipainon mittaajana, ja se soveltuu käytettäväksi useille kaupallisesti kasvatettaville lajeille, mukaan lukien kirjolohelle.

Kaksi globaalisti toimivaa yritystä, Pentair Aquatic Eco-systems ja norjalainen Vard Aqua, valmistavat kaupallista ”biomassalaskuria”, jonka toiminnallinen mittausyksikkö koostuu veden alle sijoitettavasta, optisesti kaloja skannaavasta neliskulmaisesta kehyksestä (<https://pentairaes.com/vaki-biomass-daily.html>, <http://vardaquaculture.com/en/product/biomass-estimator>). VAKI Biomass Daily -laskurille on tarjolla kolme eri kehykokoa erikokoisille kasseille, kaloille ja kalatiheyksille (esim. 0,6 × 0,65 m; VAKI 2016). Uudessaan kehyksen läpi kala osuu infrapunavalokeilaan, jolloin laite kuvaa kalan ja laskee kuvasta (luomastaan silhuetista) sen koon automaattisella kuvananalysointiohjelmalla. Laskeutusovellus kerää dataa tauotta ja koostaa siitä päivittäin kalojen keskipainon, kokojakauman, keskimääräisen kuntokertoimen ja kasvun. Tiedot siirtyvät langattomasti kustakin laskurista suoraan internetiin käyttäjien saataville (yhteenvetoreportit graafisine kuvaajineen). Raisio Aquan kokeilun perusteella tämä laite toimii kohtalaisen hyvin, mutta neuvoteltu vuokrahinta (6000 €/kassi/vuosi, sisältäen huoltopalvelun) on liian kova suomalaisiin tuotantomääriin suhteutettuna (Knut-Olof Lerche, suullinen tiedonanto 14.9.2018). Vastaava norjalainen laite ei toiminut Raisio Aquan kokeiluissa odotusten mukaisesti. Kustannuksia lisää sekin seikka, että laskuri täytyy ostaa kullekin kasvatuskassille erikseen, sillä tarpeeksi tarkan biomassadatan saamiseksi sitä täytyy pitää toiminnassa useampia viikkoja. Ei ole siis mahdollista hankkia vain yhtä laitetta ja siirrellä sitä viikoittain kassista toiseen.

Vieläkin edistyneempää teknologiaa kalojen koon ja biomassan arvioimiseksi tarjoaa uudemman sukupolven 3D-kameratekniikka, jota valmistaa esim. skotlantilainen Ace Aquatec (BioCam 3D; <https://aceaquatec.com/products/biocam>). Kyseinen kamera tuottaa yksittäisistä kaloista jatkuvan sarjan tarkkoja kolmiulotteisia kuvia (syvyyskartan) ns. lentoaikamenetelmään (time-of-flight-teknikka) perustuen ja erottelee sitten yksilöt parvesta. Kolmiulotteiset kuvat luodaan pulssitetulla vihreällä valolla, jonka toimintasäde on n. viiteen metriin asti. Syvyysmittaus perustuu reaaliaikaiseen etäisyyden mittaamiseen kuvan jokaisesta pikselistä. Näin kamera kykenee valmistajan mukaan tarjoamaan säännöllisen ja luotettavan arvion kalojen biomassasta (tai ainakin keskipainosta) kasvatuskassissa. Kiinteä IP68-tietokone tallentaa ja prosessoi datan, ja se on langattoman verkkoyhteyden ja vankkatekoisen käsitetokoneen (tabletin) välityksellä reaaliaikaisesti kasvattajien käytössä.

Kalankasvatusmarkkinoille kehitetyt 3D-kamerat eivät huomioi Suomessa kasvatettuja kalalajeja. Laskurit ovat myös verrattain kalliita, jolloin kilpailukykyisten sovellusten kehittäminen voisi lisätä niiden käyttöä ja hyötyjä. Norjalainen iTecSolutions Systems & Services AS on kehittänyt BIO3000-kuvantamislaitteiston erikseen kasvatetun lohien biomassan arvioimiseksi (<https://www.bio3000.no/home>). Valmistajan mukaan järjestelmä voi mitata jopa lähes 9000 lohta päivässä tuottaen tarkan arvion kalojen keskipainosta (± 3 %:n virhemarginaalilla, mikäli laitetta on käytetty valmistajan ohjeiden mukaisesti). Laitteisto voidaan ostaa täydellisenä pakettina (n. 30 000 € + palvelusopimus n. 1000 €/vuosi) tai vuokrata 1–3 vuodeksi (n. 1000–1300 €/kk). Raisio Aquan testissä kameran valoteho ei riittänyt edes ulkosaariston suhteellisen kirkkaassa vedessä kahta metriä syvemmälle, joten tämäkään laitteisto ei nykymuodossaan sovellu suomalaisiin tuotantolosuhteisiin, vaikka sen ohjelmisto optimoitaisiinkin erikseen myös kirjolohelle.

On hyvä huomata, että kaikki yllä esitetyt kuvausjärjestelmät keräävät aineistoa ainoastaan tietyistä kohdasta kasvatuskassia (esim. otokset kehyksen läpi uivien kalojen koosta), eivätkä ne näin ollen pysty tuottamaan täysin kokonaisvaltaista tietoa kasvatusparvesta (Folkedal ym. 2012). Toisin sanoen, tieto kalojen kokonaisbiomassasta ja lukumäärästä kullakin hetkellä nojaa siis edelleen, ainakin osittain, myös kasvattajien kokemuseräiseen arviointiin. Toisekseen, yleisiä optisten sensorien käyttöön liittyviä epävarmuustekijöitä kalaparvea kuvattaessa ovat veden aiheuttamat heijastumat sekä nk. okklusio, joka ilmenee kun useammat yksilöt liikkuvat yhdessä tai samaan aikaan lähellä toisiaan (Saberioon ym. 2017). Tuolloin kahden tai useamman kohteen erottelu ei onnistu ja ne voidaan virheellisesti mitata yhdeksi kalaksi.

Osion lopuksi on vielä todettava, etteivät nykyaikaisen kolmiulotteisen kuvauksen ja tietokonenäön kaupalliset käyttöalueet rajoitu kalankasvatuksessa yksinomaan kalojen käyttäytymisen ja kasvun seurantaan, vaan vastaavaa tekniikkaa voidaan soveltaa tuotannonohjauksessa laajemmin. Esim. norjalainen Singray Marine Solutions valmistaa erityisesti lohitäiden poistoon suunniteltua 3D-kameraa, joka on varustettu loisia kalan pinnalta poistavalla lasersäteellä (<https://www.ptgrey.com/case-study/id/10921>). Tietokoneavusteista tunnistusta voidaan hyödyntää mahdollisesti myös kasvatuskassin verkon kunnan tarkastelussa (Chalkiadakis ym. 2017) Myös uudenikäiset rokotusautomaatit hyödyntävät kalojen yksilöllistä kuvausta/mittausta, jolloin rokotus kohdistuu tarkasti oikeaan kohtaan kussakin kalassa (esim. norjalaisen Skala Maskonin rokotusautomaatti 30–170 g:n lohismolteille; <https://en.skalamaskon.no/aquaculture2/vaccination>).

2.1.3. Muita teknisiä sovelluksia ja käyttökohteita

Vaikka kalankasvatusteollisuudessa kaupallisten teknologisten sovellusten kirjo elävien kalojen seurannassa on vielä toistaiseksi jokseenkin rajoittunutta, tutkimuspuolella tähän tarkoitukseen soveltuva metodologiaa käytetään monipuolisesti. Erilaiset hydroakustiset laitteet ovat kameran sovellusten ohella useimmin käytettyjä työkaluja vesiviljelytutkimuksessa. Niiden selkeänä etuna kamerakuvaukseen verrattuna on näkyvyysolosuhteista riippumaton käyttömahdollisuus. Kaikuluotainten käyttö on ollut tämän teknologian yleisin sovellusala (Oppedal ym. 2011; Føre ym. 2018). Kaikuluotainten piirtämistä kaikugrammeista pystytään havainnoimaan kalojen pystysuuntaista jakautumista ja parveutumisen tiheyttä kasvatuskassissa. Kehittyneemmällä kaksikeilaisilla luotaimilla (split-beam sonars) voidaan arvioida myös kalayksilöiden uintinopeutta ja -suuntaa kaikukeilan sisällä (Arrhenius ym. 2000; Knudsen ym. 2004), ja edelleen monikeilaiset (multibeam) kaiut voivat tuottaa aineistoa kalojen kolmiulotteisesta levittäytymisestä ja liikkeistä kokonaisessa kassissa (Melvin 2016; Tenningen ym. 2016). Kaikuluotaintekniikkaa voidaan käyttää lisäksi yksittäisten kalojen koon arviointiin, mikäli kohteen kaikuheijastuman voimakkuuden ja pituuden tai painon välille voidaan muodostaa suhde (Knudsen ym. 2004; Soliveres ym. 2017).


Myös passiivisia hydrofoneja on käytetty saamaan tietoa useiden kalalajien (mm. lohikalat) käyttäytymiseen liittyvistä muuttujista. Tässä tapauksessa havainnointi perustuu kalojen aikaansaamiin äänien tallentamiseen, jolloin voidaan seurata esim. kalojen ruokailuaktiiviteettia (esim. AQ1 Systemsin SF500 Sound Feeding System; http://www.aq1systems.com/uploaded/271/13510009_10sf500broc_lores.pdf).

Vaikka kasvatustarvien koot ovat monesti huomattavan suuria, yksilötasoinen tieto kalojen käyttäytymisestä voi tarjota kasvattajalle yhtä lailla tärkeää tietoa kuin ryhmätasoiset indikaattorit. Akustinen telemetria on yksilöllinen kaukohavainnointimenetelmä, jossa kukin seurattava kala varustetaan elektronisella lähettimellä. Lähettimen anturit mittaavat kalan sisältä tai sen lähiympäristöstä jotain tiettyä ominaisuutta (esim. lämpötila tai sydämen syke) ja lähettävät keräämäänsä yksilödataa langattomasti (akustisin signaalein) pinnan alle kiinnitettyihin vastaanottimiin (esim. <https://www.sonotronics.com>; <http://www.htisonar.com>). Tätä teknologiaa käytetään erityisesti luonnonkalojen seurannassa mutta lisääntyvässä määrin myös vesiviljelytutkimuksessa. Kasvatustarvissa akustisen telemetrian keinoin on mahdollista saada tietoa mm. yksilöiden uinti- ja lihasaktiivisuuden tasosta, syvyysuuntaisista liikkeistä, kolmiulotteisesta asemasta sekä hengitysnopeudesta ja ravinnonotosta (esim. Cooke ym. 2004; Alfredsen ym. 2007; Rillahan ym. 2009; Føre ym. 2011, 2017, 2018; Kolarevic ym. 2016). Akustisen telemetriailaitteiston käyttöönotto edellyttää usein lähettimen kirurgista asennusta kalaan, mikä voi vaikuttaa joskus heikentävästi kalan tilaan. Vielä toistaiseksi akustinen telemetria tarjoaa kuitenkin ainoan toteuttamiskelpoisen tekniikan jatkuvaan yksilöllisen aineistosarjan keräämiseen. Lisäksi akustisella telemetrialla voidaan seurata kalan fysiologiaa – toisin kuin muilla vedenalaisen kalanhavainnointiin kehitetyillä menetelmillä, joiden käyttö rajoittuu pitkälti käyttäytymispohjaisiin muuttujiin.

Taulukko 1 vetää yhteen joitain yleisimmistä seurantamenetelmistä, joita on käytetty erityisesti kasikasvatetuille lohille (teollisesti ja tutkimuksessa käytetyt ratkaisut). Kuva 1 puolestaan havainnollistaa, kuinka näitä järjestelmiä voidaan soveltaa kaupallisessa kasvatuskassissa.

Taulukko 1. Kalankasvatusteollisuudessa ja -tutkimuksessa yleisesti käytetyt kalastonseurantajärjestelmät ja joitain niiden ominaisuuksia (Føre ym. 2018).

Sensori	Tyyppi	Mitattavat muuttujat kalastosta	Informaatiotaso	Havaitsemisalue
Kamera	Pintakamera	Pinta-aktiivisuus (hyp-piminen, loiskinta)	Ryhmä	0,5–30 m
	Ruokintakamera (upotettava)	Käyttäytymispiirteet (esim. systemaattinen vs. epänormaali uinti), ihon kunto (haavat, naarmut), lohitäiden laskenta, lajien tunnistus	Yksilöpohjainen ryhmä	0,5–25 m
	Stereo- ja 3D-kamerat (upotetut)	Samat kuin ruokintakameralla; lisäksi kalojen uinnin nopeus ja suunta sekä koon/biomassan arviointi	Yksilöpohjainen ryhmä	0,5–25 m
	Hyperspektrikuvaaja	Ihon spektriset ominaisuudet, lohitäiden havainnointi ja laskenta	Yksilöpohjainen ryhmä	0,5–25 m
	Monispektrikuvaaja	Spektristen ominaisuuksien havainnointi, lohitäiden laskenta	Yksilöpohjainen ryhmä	0,5–25 m
Kaikuluotain	Yksikeilainen luotain	Biomassan syvyysjakauma kaikukeilassa	Ryhmä	1–200 m
	Kaksikeilainen luotain	Biomassan syvyysjakauma ja liikedynamiikka (sijainti, nopeus) kaikukeilassa	Yksilöpohjainen ryhmä	1–200 m
	Monikeilainen luotain	Biomassan syvyysjakauma ja liikedynamiikka (sijainti, nopeus) koko kasvatuskassin tilavuudessa, rehurakeiden havainnointi	Ryhmä	1–200 m
Hydroakustisten telemetria	Yksilölliset lähettimet	Esim. syvyys, sijainti, kiihdyttäminen ja spatiaalinen suuntautuneisuus	Yksilöllinen historia	0–1000 m




Kuva 1. Havainnekuva, kuinka neljää erilaisin periaattein toimivaa seurantajärjestelmää voidaan hyödyntää kalankasvatuskassissa. Kun pintakamera (1), vedenalainen stereovideokamera (2) tai kaikuluotain (3) tuottavat dataa kaloista vain tietystä kassin osatilavuudesta (katkoviivoin rajatut alueet), akustisella telemetrialla (4) dataa voidaan kerätä yksittäisistä kaloista riippumatta niiden sijainnista kassissa. Kuva mukailtu Føren ym. (2018) artikkelista.

2.2. 3D-kameratekniikka

Maailma koostuu kolmiulotteisista silmillämme havaittavista objekteista. Silmälle ja kameralle tuleva kuva on kuitenkin kaksiulotteinen. Esiselvityksen tavoitteena on päästä kiinni metrisiin yksiköihin tunnistaaksemme kalojen kokoa tai liikettä, ja tähän tarvitaan kolmiulotteista dataa. Tuolloin voidaan muodostaa etäisyyksiä ja päästä kiinni mittavien suureiden keskinäisiin suhteisiin. Stereokuvauksella tuotetuista kuvista voidaan mitata tarkasteltavan kohteen etäisyyttä metrisin yksiköin suhteessa kameraan (toisin kuin 2D-kuvauksilla saadaan tuotettua vain pikselidataa). Liikkuvalla kuvalla eli kuvasarjalla päästään tutkimaan nopeutta ja sen muutoksen suhdetta (kiihtyvyyttä ja hidastuvuutta). Korostettakoon, että tämä ei siis tarkoita 3D-grafiikan luomista tietokoneohjelmalla, vaan kuvamateriaalista (2D) analysoidaan niiden kuvattua 3D-maailmaa geometrisia kulma-arvoja hyväksikäyttäen.

Esiselvityksessä oli tarkoitus hankkia tietoa yleisen 3D-tekniikan soveltuvuudesta kalojen vedenalaiseen kuvaamiseen, ja millä tavoin tuloksia voitaisiin käyttää. Tekniikaksi valittiin samankaltainen kamerajärjestelmä, jolla on tehty Australiassa onnistuneita tutkimuksia (Letessier ym. 2015; Delacy ym. 2017). Näin parannettiin hankkeen lähtökohtaisia onnistumismahdollisuuksia esiselvityksen tiedonhankinnassa.

Stereokuvat otettiin kahdella GoPro Hero2 -kameralla (Kuva 2). Kamerat olivat vesitiiviissä kotelossa, ja kamerasta toiseen kulki synkronointikaapeli. Kumpikin kamera tallensi videon omalle muistikortilleen, mutta synkronoinnin ansiosta kuvaruudut tulivat otetuksi samaan aikaan. Tämä mahdollistaa vastinpisteiden etsimisen kuvista.



Kuva 2. Kaksi GoPro Hero2 -kameraa vesitiiviissä kotelossa.

Kamerat kalibroidiin shakkiruudun avulla (Kuva 3). Ruudun mitat ovat tiedossa, joten kalibroinnin jälkeen kalojen etäisyyksiä ja pituuksia voidaan mitata millimetreissä.



Kuva 3. Stereokameran kalibrointiin käytetty shakkiruudukko.

Kalibroidulla stereokameralla voi mitata myös annetun pisteen paikka (etäisyys) suhteessa kameraan metrisesti. Edellytyksenä on, että sama piste löytyy kummastakin kuvasta. Esimerkkinä alla olevassa kuvassa 4 on kirjolohen suu (kuonon kärki). Jos myös kalan pyrstöstä olisi vastinpisteet löydettävissä, päästäisiin kiinni kalan pituuteen. Pituus olisi näiden kahden pisteen etäisyys 3D-avaruudessa. Vastaavasti saadaan määritettyä myös muita mittoja, esim. kalan korkeus.



Kuva 4. Stereokameralla otetusta kuvaruutuparista määritetyt vastinpisteet.

Liikkeen tarkastelu edellyttää, että sama piste löytyy myös seuraavasta kuvaruutuparista eli yhteensä neljästä kuvasta. Tästä saadaan yhden pisteen nopeus (metrejä sekunnissa). Kalaparven aktiivisuuden seurannassa käytettiin useaa pistettä ja näistä laskettua liikkeen keskiarvoa. Tulokset näkyvät histogrammimuodossa, jossa nopeuden muutokset havainnoituvat ajan suhteen.

2.3. Koneoppiminen

Tekoälyä voidaan kouluttaa esimerkiksi vahvistusoppimisen (reinforcement learning) avulla, jolloin dataa ei tarvita merkittävästi, mutta toimintaympäristön pitää olla selkeä ja johdonmukainen, jotta tekoälyn tekemät johtopäätökset voidaan yksiselitteisesti pisteyttää. Tällä tavoin esim. AlphaGo Zero oppi pelaamaan itseään vastaan miljoonia pelejä oppien aina vain paremmaksi (Silver et al. 2017). Koneoppimisen sisällä voi yleensä olla rakenteita, kuten päättelyä ja oppimista varten rakennetut neuroverkot.

Keinotekoiset neuroverkot (Artificial Neural Networks, ANN) juontavat juurensa vuoteen 1943. McCulloch ja Pitts (1943) tekivät tuolloin matemaattisen mallin, jossa alkukerrokseen syötetään tietoa, jonka se prosessoi sääntöjensä mukaan seuraavalle ja edelleen sitä seuraaville noodeille, kunnes viimeisessä kerroksessa saadaan ”lopputulos”, jota voidaan käyttää ”jossakin”. Neuroverkkojen adaptiivisuus tai oppiminen juontuu siitä, että eri asioille on erilaisia painoarvoja, joiden mukaan halutut tulokset vahvistavat siihen johtanutta päätöksentekopolkua. Kuitenkin alkuperäisestä ideasta matkia ihmisen aivojen toimintaa on siirrytty tiettyjen sovellusalojen suuntaan, kuten konenäköön, puheentunnistukseen, konekääntämiseen, some-suodatukseen (moderointi) ja lääketieteellisiin diagnooseihin. Näin on siis siirrytty yleisestä tekoälystä rajattuihin/spesifisiin tekoälyn sovelluksiin.

Syväoppiminen (deep learning) on alkujaan tarkoittanut tietynlaista neuroverkkorakennetta, jossa on ollut vähintään yksi piilokerros syöttö- ja tuloskerrosten välissä. Välillä neuroverkkopohjainen syväoppiminen oli ”pois muodista” niiden vaatiman laskentatehon takia. Törmäämme kuitenkin syväoppimiseen aina puhuttaessa tekoälystä tai koneoppimisesta, joiden eräänä soveltavana algoritmiluokana syväoppimista pidetään (ja niitä sekoitetaan toisiinsa).

Yksi tämän hankkeen tavoitteista oli selvittää, voisiko syväoppimistekniikoita käyttää kalan tunnistamiseen kuvasta. Tyypillisesti syväoppimisalgoritmeja käytetään kuvien luokitteluun eli tunnistamaan, mitä kuva esittää. Tässä tapauksessa tunnistettavia luokkia on vain yksi: kala. Periaatteessa tällaisella menetelmällä voisi kokeilla myös eri kalalajien tunnistamista (esim. onko kyseessä kirjolohi, kuha vai siika). Tässä vaiheessa kokeiltiin kuitenkin vain yksinkertaisempaa kalahahmon tunnistamista.

Kvanttunnistuksessa käytetty tekniikka oli YOLO (Redmon & Farhadi 2016, 2018). YOLO:a käytettiin sen nopeuden takia; videon luokittelu onnistuu reaaliaikaisesti. YOLO ei ole kuitenkaan niin tarkka kuin parhaimmat algoritmit, eikä se tunnistanut kaikkia kuvia, missä kala esiintyy.

Kuvatusta videomateriaalista otettiin kaappauskuvia, joissa kala oli hyvin näkyvässä. Osaa näistä käytettiin opettamiseen ja osaa testaamiseen. Kuvassa 5 siika on tunnistettu. Korostettakoon, että tämä prosessi ei ollut automaattinen, vaan vaatii laadukkaan datan valinnan.



Kuva 5. Kaappauskuva siiasta

3. Kalojen liikkeen havainnointi

3.1. Käytöksen luokittelu ja seuranta

Selvityksen tavoitteena oli mahdollisuuksien mukaan havaita kalojen aktiivisuudessa jonkinlaisia mitattavissa olevia muutoksia. Aktiivisuusmuutoksia pyrittiin luokittelemaan eri käytösluokkiin ja yhdistämään erilaisiin muutoksiin tai ärsykkeisiin tuotantoympäristössä (esim. ruokintaan). Tätä päätettiin selvittää aktiivisuudeltaan erilaisilla kalalajeilla (kirjolohi, kuha ja siika), jolloin mahdollisuudet erilaisiin löydöksiin ja liikedataan olisivat moninaisemmat, samalla kun lajien käyttäytymisestä saadaan lisää tietoa. Käytännössä aktiivisuutta mitattiin kalojen liikenopeuden muutoksen nopeuden avulla, mutta videoiden perusteella oli myös mahdollista seurata, miten kalojen käyttäytyminen muuttuu eri ärsykkeistä.

Oli oletettavaa, että ruokailun yhteydessä kalojen liikkeessä tapahtuisi selkeitä muutoksia, ja siten esiselvityksessä pyrittiin havainnoimaan kalojen liikenopeuden muutosta videotallenteesta ennen ruokintaa ja sen aikana. Kalojen aktiivisuus pyrittiin jakamaan komeen luokkaan: 1) normaalikäyttäytyminen, 2) käyttäytyminen ruokinnan aikana ja 3) kahdesta edellisestä poikkeava käytös.

Kalojen käyttösmuutoksia pyrittiin arvioimaan esiselvityksessä hankituista videoista. Eri lajeilta syntyi eri olosuhteissa tuotettua kuvamateriaalia; kuhia kuvattiin verrattain sameassa merivedessä Paraisilla Ammattiopisto Livian yhteydessä, siikoja Haverön Lohi Oy:n laitoksella Rymättylän Hammärönsalmessa ja kirjolohia Rymättylän Länsiaukolla välisaaristossa, jossa vesi oli hieman kirkkaampaa. Kuvamateriaalista tutkittiin 3D-havainnointiin kehitetyllä (O. Pesonen), ei-kaupallisella tietokoneohjelmalla lähinnä nopeusfunktion muutoksia. Havainnoista mielenkiintoisimmat valittiin tähän raporttiin. Paljon saatiin myös kuvamateriaalia, jossa merkittäviä aktiivisuusmuutoksia ei tapahtunut tai ei saatu riittävän selkeää kuvaa tahi kaloja näkyviin analyysin tueksi. Kirjolahien ja kuhien mittaukset ja niihin liittyvät kuvaukset järjestettiin Luonnonvarakeskuksen koetoiminnan perkuiden yhteydessä, jolloin näytekalat myös lopetettiin. Siit palautuivat takaisin kasvatuskassihinsa kuvausten ja mittausten jälkeen. Paraisilla ja Rymättylän Hammarönsalmessa koekasvatusaltaat olivat 4x4 m leveitä ja 3 m syviä vedenalaiselta osaltaan. Länsiaukolla kirjolahien (n. 1000 kpl) verkkokasvatusallas oli 8x8 m leveä ja noin 4 m syvä.

Videot kuvattiin käsivaralta kasvatusaltaan reunalta 3D-kameralla, joka oli kiinnitetty tukivarren päähän. Kuvaussyvyydet vaihtelivat 0,5–2 metriin. Kestoltaan suurin osa videoista on 1–5 minuuttia. Joukossa on joitakin noin 10 minuuttia kestäviä kuvauksia (Kuvat 6 ja 8).

3.2. Tulokset

Tietokoneella pystyttiin havainnoimaan ja luokittelemaan joitakin nopeuteen perustuvia muutoksia. Haasteena oli sekä näkyvyys että kameran saaminen riittävän lähelle kalaparvea. Kalat eivät kuitenkaan materiaalin ja kokemusten perusteella karttaneet kameraa, joten otokseen syntyi analysoitavaa materiaalia. Kasvatetut kalat, eritoten kirjolohet, olivat myöskin jossain määrin tottuneet ihmisen läsnäoloon, eikä se oletettavasti aiheuttanut suurta käytöksen muutosta.

Kalan liikkuminen kameran ohi tapahtui yleensä nopeasti (pois lukien kuha). Parven liikkumista, jossa samoja kaloja näkyisi pitkään liikkeessä samalla videolla, ei syntynyt paljoakaan. Tämä johtui luultavimmin sameista kasvatusolosuhteista sekä käytetyn kameran kuvauskyvystä. Saman parven ja kalalajin kaikki kalat kuitenkin ”vilahtivat” kameran ohi suunnilleen samoilla nopeuksilla, jolloin

histogrammin nopeusluokka oli mitattavissa ja toimi näin ollen hyvin nopeuden määrittelyn ja havainnon tukena.

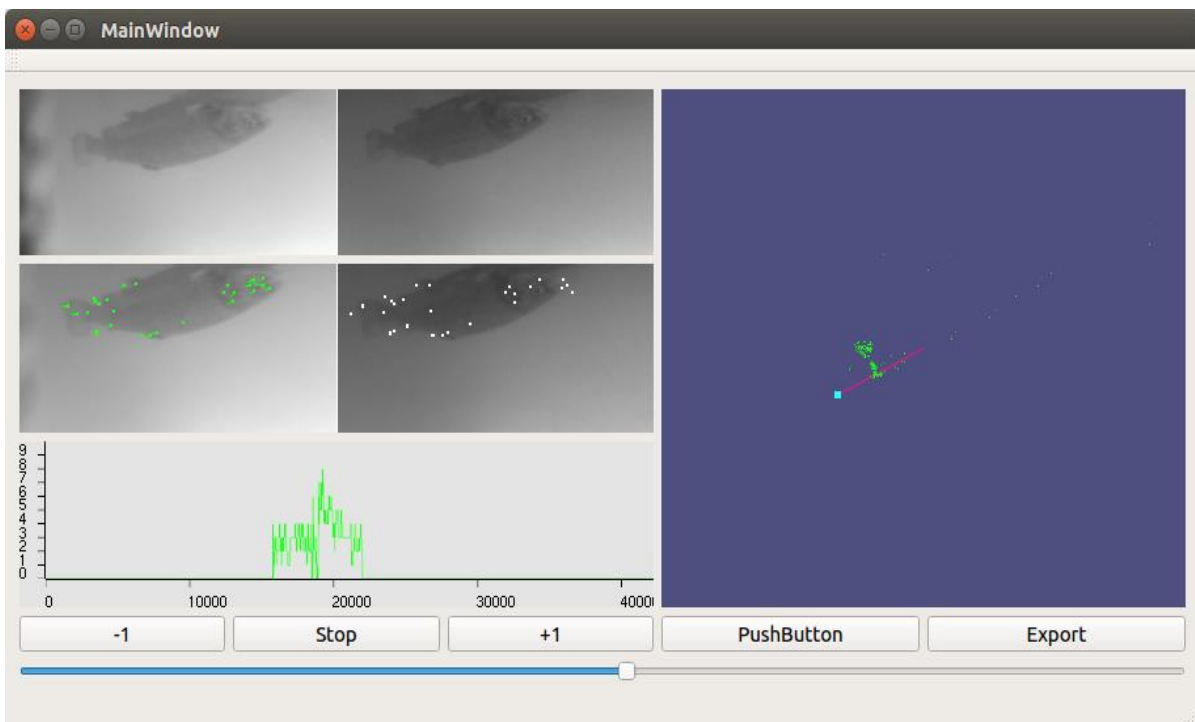
Kirjolohen ja siian kuvamateriaalista 3D-videokuvasta pystyttiin erottamaan myös aktiivisuuden muutokset esimerkiksi ruokinnan käynnistyttyä, kun tutkittiin nopeuden muutoksia. Aktiivisuuden luokitteluun ja sen tarkkuuteen tarvittaisiin kuitenkin suurempi määrä dataa, jotta varmuudella voitaisiin muodostaa luokittelua normaaliaktiivisuudesta, ruokailuaktiivisuudesta jne.

Alla on kerrottu tarkemmin kustakin kuvatusta kalalajista tehdyt havainnot.

3.2.1. Kirjolohi

Kohdekaloja kuvattiin Rymättylän Länsiaukolla sijaitsevalla pienellä verkkokassilaitoksella. Kuvauksia suoritettiin kolmena eri kertana: 24.9.2018 (klo 7.50–13.00; sää aurinkoinen), 14.11.2018 (klo 10.30–14.30; sää pilvinen) ja 20.12.2018 (klo 10.00–14.30; sää pilvinen). Kalojen paino oli kuvauksia suoritettaessa syksyllä suunnilleen 1 kg tai hieman alle. Ensimmäisellä seurantakerralla kaloja ruokittiin automaattiruokkimin ja kalojen havaittiin aktivoituvan ruokintaan hyvin. Toisella kuvauskerralla kaloja ruokittiin käsin niiden kylläisyyteen asti, ja silmämääräistä aktiviteetin laskua pinnassa oli havaittavissa ruokinnan lopussa. Selkeä aktivoituminen näkyi ruokailun alussa. Kolmannella kuvauskerralla joulukuussa kaloja ei enää ruokittu, koska ne oli siirretty paastolle.

Videoista syntyneitä aktiviteettihistogrammeja vertailemalla pystyttiin toteamaan, että ruokinnan aikana kalojen aktiivisuus (nopeus) lisääntyy (Kuva 6). Ruokinta-ajankohdat varmennettiin ajallisesti videolla näkyvien, alaspäin vajoavien rehupellettien perusteella.



Kuva 6. Kirjolohia Rymättylässä 24.09.2018 kuvattuna. Havainto: Parvi oli aktiivinen ja ruokaili aktiivisesti. Kuvassa ylävasemmalla alkuperäiset stereokuvat harmaasävynä. Oikealla mitatut 3D-etäisyydet (sinisellä taustalla). Vasemmalla alhaalla on kuvattu keskimääräinen nopeus (y-akseli) ajan funktiona (x-akseli). Liikkeen nopeuspiikki osuu ruokailuajankohdan kohdalle.

3.2.2. Kuha

Kuhien liikkeistä videomateriaalia kerättiin kaksi kertaa Luken Paraisten koetoimintayksikössä, joka sijaitsee Livian ammattiopiston yhteydessä. Kuvauksia suoritettiin 17.9.2018 (klo 7.10–10.30; sää pilvinen) ja 21.9.2018 (klo 7.10–8.30; sää pilvinen ja kevyttä sadetta). Kuhien ruokinta tapahtui automaateilla normaalisti aamulla klo 7–9 ja illalla klo 19–21, mutta ensimmäisen kuvauksen ohessa kaloille annettiin vielä lisäruokintaa aamuruokinnan jälkeen. Kuvauksissa syntynyt videomateriaali oli lähtökohtaisesti hyvin heikkoa veden huomattavan sameuden takia. Ensimmäisellä kuvauskerralla näkösyvyys valkolevyllä mitattuna oli 0,95 m ja toisella 0,8 m. Lisäksi kuhat tuntuivat viihtyvän odotusten mukaisesti valtaosin paikallaan. Joissain videoissa kuha kävi vähän aikaa kameran edessä (Kuva 7); ei kuitenkaan niin pitkää aikaa, että liikehistogrammia olisi pystynyt laskemaan. Histogrammi pohjautuu keskiarvon laskemiseen, ja yksi kala edustaa huonosti koko parven aktiivisuutta. Luotettavaa yleistystä ei siten pystytty tällä materiaalilla tuottamaan. Kuvatut kuhat olivat keskipainoltaan n. 350–400 gramman painoisia. Osasta kaloja todettiin, etteivät ne pääsääntöisesti syöneet kasvatuskauden aikana, ja olivat näin syksyllä keskimäärin laihempia kuin lähtötilanteessa. Tämä selitti näiden kuhien passiivisuutta myös ruokinnan aikana.

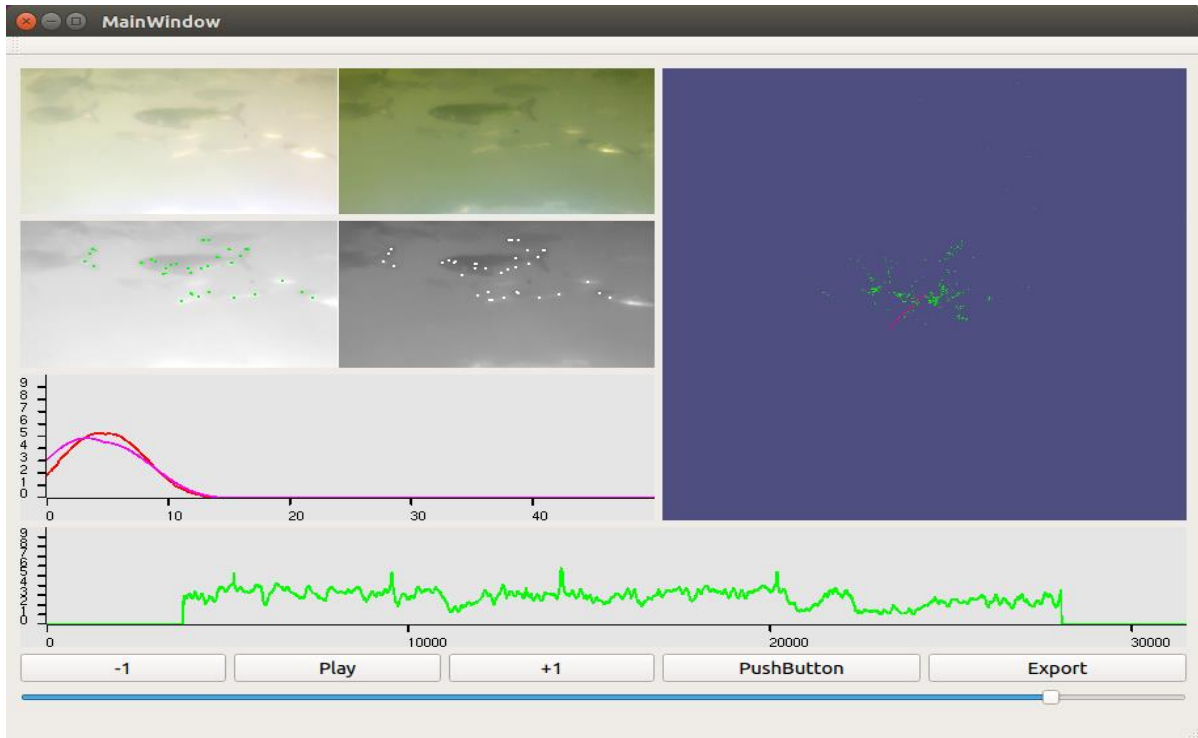


Kuva 7. Kuha Paraisten kasvatuskassissa 21.9.2018 kuvattuna.

3.2.3. Siika

Siikoja kuvattiin elo- ja syyskuussa 2018 Rymättylän koeyskikössä, jossa niitä kasvatettiin ruokintakokeita varten. Ruokinta suoritettiin automaateilla kolmessa jaksossa: klo 8.00–10.54, 10.54–11.47 ja 16.39–18.00. Elokuun videokuvaus suoritettiin 22. päivä kuvaamalla kesänvanhoja siikoja (n. 30–40 g) ja 1 vuoden ikäisiä siikoja (n. 80–130 g). Kuvaus suoritettiin klo 10.30–12.30 välisenä aikana. Sää oli kuvaushetkellä aurinkoinen. Syyskuussa kuvaus tehtiin 25. päivä (klo 7.50–12.00). Tällöin näkösyvyys valkolevyllä mitattuna oli 1,3 m, ja sää oli puolipilvinen. Siikoja kuvattiin syyskuussa ensin ennen aamuruokinnan alkamista ja kuvausta jatkettiin ruokinnan käynnistyttyä, jolloin voitiin havainnoida liikkeen muutos. Kuvattavat siiat olivat tuolloin painoltaan noin 190 g. Ensin kuvausta tehtiin siis aktiviteetin tunnistamista varten, mutta tämän jälkeen seitsemän yksilöä siirrettiin saavissa mittauksiin (pituus ja paino). Kukin näistä siioista kuvattiin saavissa yksittäin ja lisäksi kolmen saavin järjestelyllä tuotettiin kuvamateriaalia kalapareista jatkokehitystä eli yksilötunnistamista ajatellen. Fyysisiä mittaustuloksia verrattiin 3D-materiaalista tehtyyn analyysiin.

Siiat uivat parvena tasaisen rauhallisesti, ja ne aktivoituivat ruokintaan. Videomateriaalin analyysissä havaittiin, että toisin kuin kirjolohi, siika ”hidastaa” uintinopeuttaan syömisen yhteydessä (Kuva 8). Nopeuden näennäinen muutos analyysissä voi johtua siian liikkeen muutoksesta ruokailun alkaessa: ruokailujen välillä siiat uivat tyypillisesti tasaisesti ympyrää, ruokailun aikana kalat tekevät nopeita suunnanmuutoksia pellettejä napatakseen.



Kuva 8. Siikoja Rymättylässä 25.9.2018. Kalat kuvattu noin 2 metrin syvyydessä. Havainto: Parvi oli aktiivinen ja ruokaili aktiivisesti. Kuvassa ylävasemmalla alkuperäiset stereokuvat värikuvana ja sen alla oikaistut stereokuvat harmaasävyinä. Oikealla mitatut 3D-etäisyydet. Stereokuvien alla on keskiarvoistettu liike (violetit gaussin käyrät) yhden kuvaruudun aikana (tiettyinä ajanhetkenä). Alimpana keskimääräinen nopeus (y-akseli) kuvattuna ajan funktiona (x-akseli). Kuvassa kalojen ruokinta on osunut kohdan "20000" jälkeen, jolloin nähdään liikkeen hidastuminen.

4. Kalojen koon arviointi

4.1. Tarve

Kalojen ruokintaa säädellään paitsi arvioidun ruokailuaktiivisuuden (rehunkulutuksen) myös annetun rehun arvioituna siirtymisenä kalan painoon (rehukertoimen perusteella). Tutkimusten ja käytännön kokemuksen avulla on saatu luotettavia taulukoita eri kalalajien rehun muuntotehokkuudesta niiden kasvuun (annetun rehun suhde biomassan lisäykseen). Kasvatuksen aikana voidaan arvojen tarkistuksessa käyttää välimittauksia, jolloin edustava otos kaloja punnitaan.

Kalojen koon (pituuden) arvioinnilla haettiin vastausta kysymykseen, voiko 3D-kuvamateriaalista saada tietoa, jolla pystyisi tarkentamaan verkkokassissa kasvatettujen kalojen kasvutietoa, ja toiseksi, mikä olisi tämän tiedon tarkkuus suhteessa kalojen manuaalisesta mittaamisesta saatuun tietoon. Esiselvityksessä keskityttiin ensin ainoastaan kalojen pituuden mittaamiseen tietokoneella, vaikka hyvin tiedostettiin että kokonaisvaltaisemmalla arviolla kalan muodosta päästään tarkempaan arvioon kalan loppupainosta. Tämä olisi kuitenkin vaatinut kalalajikohtaista tarkempaa tutkimusta niistä kalan havaintopisteistä, joista tietokone voi tunnistaa kalan muodon. Tämä edelleen mahdollistaa tarkempien painoalgoritmien laatimisen.

4.2. 3D-mittaukset

Kalibroidulla stereokameralla tuotettua materiaalia voidaan tutkia kolmiulotteisesti. Niin ikään materiaalista saadaan metrisiä mittauksia kuten kalan pituus. Kuvaparista valitaan pisteet, joiden välinen etäisyys halutaan mitata (esim. kalan kuonon kärki ja pyrstö).


Kolmelta kalalajilta pyrittiin saamaan pituustietoja, josta voitaisiin päätellä alustavasti kalojen kokoa (lähinnä painoa). Kuvaukset toteutettiin saaveissa pienelle määrälle yksilöitä per kalalaji. Kuvatuilta kaloilta määritettiin samalla kokonaispituus kuonon kärjestä pyrstön kärkeen (mm:n tarkkuudella) ja paino (g:n tarkkuudella) perinteisin fyysisin mittauksin.

4.3. Tulokset

Tulokset on esitetty alla kalalajeittain ja niillä haettiin alustavaa indikaatiota 3D-datan sopivuudesta kalan koon arviointiin. Kiinnostus oli, miten biomassan arvioimiseen voitaisiin päästä käsiksi tekoälyavusteisesti. Metrinen yksiköiden pituusdataa saatiin luotettavasti. Data oli kuitenkin käsiteltävä manuaalisesti, eli yksilö piti valita videokuvasta ja mitata halutut dimensiot. Itse dimensiot osoittautuivat tarkoiksi ja paikkansa pitäviksi käsimittauksiin verraten. Esiselvityksen pienillä havaintomäärillä ja kalan pituusperusteisilla mittauksilla ei kuitenkaan pystytä kehittämään luotettavaa mittausalgoritmia vielä tässä vaiheessa.

4.3.1 Kirjolohi


Kirjolohista kuvattiin otokset Rymättylässä 24.09.18 (3 kpl) ja 20.12.2018 (7 kpl). Kirjolohen kohdalla päästiin hyvin toisiansa vastaaviin mittaustuloksiin (3D- vs. fyysinen mittaustulos) molemmilla kuvauskerroilla (Kuva 9).



Kuva 9. Kirjolohien yksilöpituudet 3D-kuvauksiin (arvio) ja fyysisiin mittauksiin perustuen.

4.3.1. Kuha

Neljätoista kuhaa kuvattiin Paraisilla 3.10.2018. Veden sameudesta johtuen vain viidestä saatiin onnistuneet kuvat, joita voitiin verrata fyysisiin mittaustuloksiin. Näiden kohdalla päästiin hyvin toisiansa vastaaviin mittaustuloksiin (3D- vs. fyysinen mittaus; Kuva 10).




Kuva 10. Kuhien yksilöpituudet 3D-kuvauksiin (arvio) ja fyysisiin mittauksiin perustuen.

4.3.2. Siika

Siikat kuvattiin Rymättylässä 25.9.2018. Seitsemän kalaa poimittiin tuolloin haavilla saaviin ja siirtojen avulla saatiin kuvamateriaali jokaisesta yksilöstä erikseen ja eri kalakombinaatioista yhdessä.

Myös siikojen kohdalla päästiin toisiansa vastaaviin pituusmittoihin (3D- vs. fyysinen mittaus; Kuva 11).



Kuva 11. Siikojen yksilöpituudet 3D-kuvauksiin (arvio) ja fyysisiin mittauksiin perustuen.

5. Lisäselvitystarpeet?

Tässä kappaleessa pohditaan, miten esiselvityksen tiedot antavat aihetta jatkokehitykselle. Kotimaisen kalankasvatuksen haastavat olosuhteet, eli lähinnä veden huono näkyvyys, olivat ennakkoon tiedossa. Kehittyneemmällä kamerajärjestelmällä olisi mahdollista parantaa datan määrää ja laatua, jolloin myös analysoitu aineisto olisi luotettavampi. Wifi-kuvalinkitysteknologialla voitaisiin saada aina kaloja videolle, jolloin aineiston laatu kasvaisi, eikä kuvausta tarvitsisi tehdä ns. sokkona. Toinen kamerajärjestelmän kehitystä koskeva ehdotus olisi laajempi spektri (ml. infrapuna-alue) tai eräänlainen hybriditeknologia (tai kahden eri teknologian tuoman datan yhteisanalyysi).

Kirjolohesta ja siiasta saatiin laadukkaimmat aineistot jatkokehitystä varten. Kuhasta ei sitä vastoin paljoa lisätietoa kertynyt, koska vesi oli sameampaa ja kalat passiivisempia. Huonon kuvalaadun ja näkyvyyden aiheuttaman haasteen ratkaisemiseksi olisi tarpeen miettiä sameiden vesien ”läpäiseviä” teknologioita ja yhdistää niitä koneoppimiseen.

Siian ja kirjolohen osalta liikkeen tunnistamiseen liittyvät tulokset olivat lupaavia: niiden perusteella voisi kehittää tunnistimia, joilla arvioidaan esimerkiksi kalojen ruokahalu- tai stressikäyttäytymistä tai ruokintalaitteiden toimivuutta. Liiketunnistamisen luokittelua voisi parantaa altistamalla kaloja erilaisille häiriötekijöille. Edelleen ruokinnan ja kalojen käyttäytymisen muutosta voitaisiin analysoida tarkemmin erityisesti kylläisyyteen asti tapahtuvan ruokinnan yhteydessä. 3D-kuvausmateriaali sopisi hyvin mm. ruokintakokeiden yhteyteen antamaan liikedataa, mikäli kalojen kylläisyys korreloi suoraan nopeuden muutoksiin. Tätä havaintoa ei ole vielä todistettu isolla aineistolla.

Biomassalaskuria varten tarvitaan paljon materiaalia edes verrattain luotettavien painoalgoritmien laatimiseen. Esiselvityksen data-analyysin perusteella ei kyetä vielä edes arvioimaan, päästäänkö luotettavuudessa riittävän hyvälle tasolle siten, että siitä olisi käytännössä hyötyä, vaikka 3D:llä pystyttäisiin paremmin arvioimaan kalan koon suhde sen painoon. Tietokoneelle tulisi opettaa kalalajikohtaisesti ne pisteet, jonka perusteella koneäly arvioisi kalan koon ja edelleen sen painon.

Tekoälyä soveltavan autonomisen laskurin opettaminen on mahdollista kalojen pituuksia määrittäessä. Olemassaolevasta materiaalista pystyttiin tunnistamaan tekoälyllä yksittäisiä kaloja. Neuroverkkoa voidaan ajatella opetettavan tekemään mittauksia tunnistamalla kunkin poimitun kalan kuvasta sen kuonon ja pystön ja laskemaan niiden välisen etäisyyden. 3D-videosta on mahdollista työstää myös ”elokuvatheaterimaista” tilavuuskuvaa, mutta kalojen eri dimensioiden laskemiseen siitä ei ole vielä arvioita.

Hankkeen aikana järjestettiin työpaja asiantuntijoille, joilla oli kehitystarpeita koneällyn hyödyntämisestä kalatalouden sovelluksiin; työpajassa ja hankkeen aikana nousi esille myös muita mielenkiintoisia kysymyksiä ja mahdollisia sovelluksia, kuten:

- Kasvatuskassin verkon eheyden tarkistamiseen soveltuvan algoritmin kehittäminen
- Biomassalaskuri, joka laskee kalojen kasvun muutoksen päivittäin tapahtuvan ruokinnan yhteydessä
- Kuinka hyljehäiriöiden ja -vaurioiden todentaminen voisi tapahtua reaaliaikaisesti?
- Sopsisiko konenäön tarkkuus emokalojen tunnistamiseen esim. kalaportaissa?
- Miten kaikuluotaus- ja kuvadataa voisi yhdistää (vrt. UTOFIA-projekti)?
- Saisiko jotenkin tallennettua tietoa siitä, että etäällä tapahtunut automaattinen ruokinta on ylipäätään onnistunut ja tapahtunut?
- Minkälainen olisi järjestelmä, jossa joitakin näitä ominaisuuksia yhdistettäisiin?

Kysymykseen, missä tarvittava data analysoitaisiin tai minne se lähetettäisiin analysoitavaksi, törmättiin, kun pohdittiin tiedonsiirron haasteita. Samalla arvioitiin, olisivatko kiinteät laitteet (jotka mittaisivat lähinnä ruokinnan onnistumista silloin kun ihminen ei ole valvomassa) tai veneen mukana pidettävillä siirrettävillä biomassalaskureilla enemmän kysyntää. Sovelluksien skaalautuvuuden mahdollisuudet olisivat enemmän vientimarkkinoilla, jolloin sovellusten tulisi toimia eri kalalajeilla. Tärkeimmillä kalalajeilla olisi laitteille lisää kysyntää, mutta toisaalta niiden ruokinta ym. käyttäytyminen on paremmin tiedossa, jolloin laitteista olisi kenties enemmän hyötyä esimerkiksi siian ja kuhan ruokinnassa (kotimaisia kasvatustilajeja seurattaessa).

Tässä esiselvityksessä kalojen käyttäytymisdataa saatiin ja käsiteltiin vähän. ”Big datan” keräämisen kautta ja koneoppimisen avulla voisi mahdollisesti löytää jotain piilossa olevaa tietoa kalojen käyttäytymisestä. Yleisesti kaiken datan moniulotteinen analyysi olisi omiaan suoritettavaksi juuri koneoppimisen avulla, mutta se vaatisi paljon aineistoa ja monia oppimiskierroksia ilman että lopputuloksen hyödyllisyydestä olisi mitään takeita. Myös asiantuntemusta kalojen käyttäytymisessä tarvitaan sikäli, jos koneella havaitaan poikkeavaa käyttäytymistä, mikä vaatii selitystä.

Teknologiaa on maailmalla saatavana ja kotimaassakin löytyy osaajia tekoälyn, koneoppimisen ja konenäön saralla. Sivusta katsominen takaa vain teknologian ostajan roolin, eikä kotimaisilla tuotteilla pääse kilpailemaan markkinoilla. Yhteistyössä eri sidosryhmien kanssa voidaan päästä edistämään teknologiakehitystä kalatalouteen liittyvän datan keruussa ja eritoten hyödyntämisessä. Kalankasvatus on maailmanlaajuisesti nopeimmin kasvava elintarviketuotantomuoto, jolloin olisi edelleen syytä arvioida kyseisten sovellusten kysyntää kotimaassa ja maailmalla.

6. Yhteenveto

Tällä esiselvityksellä pyrittiin saamaan tietoa 3D-kuvaustekniikan soveltuvuudesta suomalaisessa kalankasvatusympäristössä. Tarkoitus oli esiselvittää, voisiko kalojen aktiivisuudesta kehittää koneoppimisen avulla parempia ratkaisuja kalateollisuudelle, mahdollistaisiko 3D-teknologia esim. biomassalaskureiden kehittämisen sille tarkkuustasolle, että niitä voitaisiin hyödyntää tuotannon tehostamisessa, tai mitä muita mahdollisia sovellusaloja tahi jatkokehittävää tarvittaisiin lisätiedon hankkimiseksi.

Veden sameus mantereen lähellä oli ennalta tiedossa, ja sen aiheuttama heikko näkyvyys vaikutti kuvausten onnistumiseen etenkin Paraisilla kuhankasvatusta videoitaessa. Ulkosaariston kirkaissa vesissä ei tässä hankkeessa kaloja kuvattu, mutta sisä- ja välisaariston kuvausten perusteella voidaan arvioida, että niin liikkeen kuin kalan koonkin tunnistaminen helpottuu näkyvyyden parantuessa. Kankainen (2015) ja Kankainen ym. (2019) ovat arvioineet eri vedenalaiskameratekniikalla, miten sameus vaikuttaa vedenalaiskameroiden hyödyntämiseen.

Kaloista saatiin liikedataa, josta pystyttiin toteamaan aktiviteetin muutoksia sekä manuaalisesti näytöltä että ”puoli-automaattisesti” videodatan avulla. Datamäärät jäivät kuitenkin verrattain pieneksi mallintamista ajatellen. Havainnot ruokailevista kirjolohista vastasivat odotuksia, koska kirjolohi tunnetusti liikkuu aggressiivisesti ruokailun käynnistyttyä. Myöskään kuhien rauhallinen liikehdintä ei ruokintakoeympäristössä yllättänyt. Sen sijaan siikojen ”hidastaminen” syömisen yhteydessä tuli uutena, yllättävänä havaintona, mikä antaisi hyvän tarkentavan jatkoselvitysaiheen.

Käytetty 3D-kuvaustekniikka ja kamerasovellus täytti perustehtävänsä kalojen pituuden mittaamiseen liittyen: kaikista kuvatuista kalalajeista saatiin metrisiä pituusmittoja, jotka vastasivat käsin tehtyjä vertausmittauksia. Vaikka näytemäärä ei ollut suuri, se antoi hyvää osviittaa menetelmän mahdollisesta tarkkuudesta. Voidaankin todeta, että 3D-kuvatuista kaloista saadut mitat ovat sen verran todenperäisiä, että 3D-kuvaa voitaisiin käyttää kalojen pituuden tarkempaan arviointiin. Kalojen painonarviointiin tarvitaan lisätietoa ja koneopettamista kalojen muodosta ja painosta.

Yhtenä näkökulmana ja mahdollisena sovelluksena selvitettiin edellytyksiä biomassalaskurin toteuttamiseksi. Puoliautomaattinen datan keruu on mahdollista käytetyllä kuvausteknologialla. Datan määrää kasvattamalla voitaisiin ehkä päästä tarkempiin arvioihin koko populaation koosta. Ja päivittäisellä esimerkiksi ruokinnan yhteydessä tapahtuvalla seurannalla voitaisiin parantaa kalan kasvutietoa tilastollisesti. Itse algoritmin kehittämiseen ja opetusdatan hankkimiseen kannattaa varata vähintäänkin yksi kalojen kasvukausi muutamassa eri paikassa siten, että videokuvaa kerätään säännöllisesti.

Yhteistyönä tehtäviä jatkoselvitystarpeita, joille olisi mahdollisesti kysyntää ensisijaisesti kalankasvatukseen liittyvissä sovelluksissa, olisi 3D-biomassalaskuriin sekä etäruokintaan ja kalojen käyttäytymiseen liittyvien sovellusten kehittäminen.

Viitteet

- Airaksinen, S., Norrdahl, O., Paasilta, M., Riihimäki, J., Ruohonen, K., Setälä, J. & Vaajala, M. 2003. Itseohjautuva ruokinta kirjoloihen verkkoallasviljelyssä (ITSE). Kala ja riistaraportteja 288. 31 s.
- Alfredsen, J.A., Holand, B., Solvang-Garten, T. & Uglem, I. 2007. Feeding activity and opercular pressure transients in Atlantic salmon (*Salmo salar* L.): Application to feeding management in fish farming. *Hydrobiologia* 582: 199–207.
- Arrhenius, F., Benneheij, B.J., Rudstam, L.G. & Boisclair, D. 2000. Can stationary bottom split-beam hydroacoustics be used to measure fish swimming speed in situ? *Fisheries Research* 45: 31–41.
- Beddow T.A., Ross L.G. & Marchant J.A. 1996. Predicting salmon biomass remotely using a digital stereo-imaging technique. *Aquaculture* 146: 189–203.
- Chalkiadakis, V., Papandroulakis, N., Livanos, G., Moirogiorgou, K., Giakos, G. & Zervakis, M. 2017. Designing a small-sized autonomous underwater vehicle architecture for regular periodic fish-cage net inspection. IEEE International Conference on Imaging Systems and Techniques (IST). Beijing, China, October 18–20, 2017. IEEE.
- Cooke, S.J., Thorstad, E.B. & Hinch, S.G. 2004. Activity and energetics of free-swimming fish: Insights from electromyogram telemetry. *Fish and Fisheries* 5: 21–52.
- Costa, C., Loy, A., Cataudella, S., Davis, D. & Scardi, M. 2006. Extracting fish size using a dual underwater cameras. *Aquaculture Engineering* 35: 218–227.
- Delacy, C., Olsen, A., Howey, L., Chapman, D., Brooks, E. & Bond, M. 2017. Affordable and accurate stereo-video system for measuring dimensions underwater: A case study using oceanic whitetip sharks *Carcharhinus longimanus*. *Marine Ecology Progress Series* 574: 75–84.
- Duarte, S., Reig, L. & Oca, J. 2009. Measurement of sole activity by digital image analysis. *Aquaculture Engineering* 41: 22–27.
- Folkedal, O., Stien, L.H., Nilsson, J., Torgersen, T., Fosseidengen, J.E. & Oppedal, F. 2012. Sea caged Atlantic salmon display size-dependent swimming depth. *Aquatic Living Resources* 25: 143–149.
- Føre, M., Alfredsen, J.A. & Gronningsater, A. 2011. Development of two telemetry-based systems for monitoring the feeding behaviour of Atlantic salmon (*Salmo salar* L.) in aquaculture sea-cages. *Computers and Electronics in Agriculture* 76: 240–251.
- Føre, M., Frank, K., Dempster, T., Alfredsen, J.A. & Høy, E. 2017. Biomonitoring using tagged sentinel fish and acoustic telemetry in commercial salmon aquaculture: A feasibility study. *Aquacultural Engineering* 78: 163–172. Part B.
- Føre, M., Frank, K., Norton, T., Svedsen, E., Alfredsen, J.A., Dempster, T. ym. 2018. Precision fish farming: A new framework to improve production in aquaculture. *Biosystems Engineering* 173: 176–193.
- Hao, M., Yu, H. & Li, D. 2016. The measurement of fish size by machine vision – a review. Teoksessa: Computer and computing technologies in agriculture IX: 9th IFIP WG 5.14 international conference, CCTA 2015, Beijing, China, September 27–30, 2015, revised selected papers, Part II 9 (s. 15–32). Springer International Publishing.
- Kankainen, M. 2015. Ympäristötehokas kalankasvatus ja ympäristövaikutusseurantamenetelmien kehittäminen. Loppuraportti. Luonnonvarakeskus.
- Kankainen, M., Tuppurainen, V. & Niukko, J. 2019. Kokemuksia kameraseurannan hyödyntämisestä kalankasvatuksessa Itämerellä. Luonnonvarakeskus, Luonnonvara- ja biotalouden tutkimus 19/2019.
- Knudsen, F.R., Fosseidengen, J.E., Oppedal, F., Karlsen, Ø. & Ona, E. 2004. Hydroacoustic monitoring of fish in sea cages: Target strength (TS) measurements on Atlantic salmon (*Salmo salar*). *Fisheries Research* 69: 205–209.
- Kolarevic, J., Aas-Hansen, Ø., Espmark, Å., Baeverfjord, G., Terjesen, B.F. & Damsgård, B. 2016. The use of acoustic acceleration transmitter tags for monitoring of Atlantic salmon swimming activity in recirculating aquaculture systems (RAS). *Aquacultural Engineering* 72: 30–39.

- Letessier, T.B., Juhel, J.-B., Vigliola, L. & Meeuwig, J.J. 2015. Low-cost small action cameras in stereo generates accurate underwater measurements of fish. *Journal of Experimental Marine Biology and Ecology* 466: 120–126.
- Mathiassen, J.R., Misimi, E., Bondo, M., Veliyulin, E. & Ostvik, S.O. 2011. Trends in application of imaging technologies to inspection of fish and fish products. *Trends in Food Science & Technology* 22: 257–275.
- McCulloch, W.S. & Pitts, W.H. 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5: 115–133.
- Melvin, G.D. 2016. Observations of in situ Atlantic bluefin tuna (*Thunnus thynnus*) with 500-kHz multibeam sonar. *ICES Journal of Marine Science: Journal du Conseil* 73: 1975–1986.
- Niu, B., Li, G., Peng, F., Wu, J., Zhang, L. & Zhenbo, L. 2018. Survey of fish behavior analysis by computer vision. *Journal of Aquaculture Research & Development* 9: 534.
- Oppedal, F., Dempster, T. & Stien, L.H. 2011. Environmental drivers of Atlantic salmon behaviour in sea-cages: A review. *Aquaculture* 311: 1–18.
- Patullo, B.W., Jolley-Rogers, G. & Macmillan, D.L. 2007. Video tracking in the extreme: video analysis for nocturnal underwater animal movement. *Behavior Research* 39: 783–788.
- Pinkiewicz, T.H., Purser, G.J. & Williams, R.N. 2011. A computer vision system to analyse the swimming behaviour of farmed fish in commercial aquaculture facilities: A case study using cage-held Atlantic salmon. *Aquaculture Engineering* 45: 20–27.
- Redmon, J. & Farhadi, A. 2016. YOLO9000: Better, Faster, Stronger. *ArXiv161208242 Cs*.
- Redmon, J. & Farhadi, A. 2018. YOLOv3: An Incremental Improvement. *ArXiv180402767 Cs*.
- Rillahan, C., Chambers, M., Howell, W.H. & Watson, W.H. 2009. A self-contained system for observing and quantifying the behavior of Atlantic cod, *Gadus morhua*, in an offshore aquaculture cage. *Aquaculture* 293: 49–56.
- Saberioon, M., Gholizadeh, A., Cisar, P., Pautsina, A. & Urban, J. 2017. Application of machine vision system in aquaculture with emphasis on fish: state-of-the-art and key issues. *Reviews in Aquaculture* 9: 369–387.
- Silver, D., Schrittwieser J., Simonyan K., Antonoglou I., Huang A. ym. 2017. Mastering the game of Go without human knowledge. *Nature* 550: 354–359.
- Soliveres, E., Poveda, P., Estruch, V.D., Pérez-Arjona, I., Puig, V., Ordóñez, P. ym. 2017. Monitoring fish weight using pulse-echo waveform metrics. *Aquacultural Engineering* 77: 125–131.
- Tenningen, M., Macaulay, G.J., Rieucan, G., Peña, H. & Korneliussen, R.J. 2016. Behaviours of Atlantic herring and mackerel in a purse-seine net, observed using multibeam sonar. *ICES Journal of Marine Science: Journal du Conseil* 74: 359–368.
- VAKI Aquaculture Systems. 2016. Biomassdaily User's Manual, s. 5–15.
- van Rooij, J.M. & Videler, J.J. 1996. A simple field method for stereo-photographic length measurement of free-swimming fish: merits and constraints. *Journal of Experimental Marine Biology and Ecology* 195: 237–249.
- Zion, B. 2012. The use of computer vision technologies in aquaculture – A review. *Computers and Electronics in Agriculture* 88: 125–132.



luke.fi

Luonnonvarakeskus
Latokartanonkaari 9
00790 Helsinki
puh. 029 532 6000