

Eemeli Ollila, Iikka Keltto, Aatu Klasila, Paulus Piilonen

KONENÄKÖRATKAISUT KALASAALIIN TUNNISTAMISEEN

KONENÄKÖRATKAISUT KALASAALIIN TUNNISTAMISEEN

Eemeli Ollila
Iikka Keltto
Aatu Klasila
Paulus Piilonen

Tutkielmaraportti
Elektroniikka ja ohjelmointi -opintojakso
Kevät 2021
Konetekniikan tutkinto-ohjelma
Oulun ammattikorkeakoulu

SISÄLLYS

SISÄLLYS	2
1 JOHDANTO	3
2 KONENÄKÖMENETELMÄT	4
2.1 Perinteinen 2D-konenäkö	4
2.2 Spektrikuvantaminen	5
2.3 Tekoälyn hyödyntäminen	6
2.4 Neuroverkko kuvantunnistuksessa	6
3 VALAISTUSMENETELMÄT	8
3.1 Taustavalaistus	8
3.2 Suoravalaistus	8
3.3 Tumma taustavalaistus	8
3.4 Polarisoitu valaistus	8
3.5 Värisuodatettu valaistus	9
3.6 Epäsuora valaistus	9
4 VALMIIT RATKAISUT	10
4.1 SICK	10
4.2 Beckhoff	11
4.3 OEM	13
5 YHTEENVETO	15
LÄHTEET	16

1 JOHDANTO

Tämä raportti käsittelee tutkimustyötä, joka on toteutettu Oulun ammattikorkeakoulun (OAMK) konetekniikan tutkinto-ohjelman kurssilla ”TK00BP62 Elektroniikka ja Ohjelmointi”. Työ tehtiin neljän hengen ryhmässä, jossa mukana olivat Eemeli Ollila, Iikka Keltto, Aatu Klasila, Paulus Piilonen. Tutkimustyön ohjaajana sekä kurssin opettajana toimi lehtori Juha Junttila.

Työssä tutkitaan millä konenäkömenetelmillä kalojen lajitunnistus voitaisiin toteuttaa. Tekemämme esiselvitys on osa kotimaisen kalan isovolyymisen automaattilajittelulinjan selvitystyötä. Tämän lisäksi tarkastelemme mitä valmiita tekniikoita ja järjestelmiä on jo olemassa, ja mitkä ovat arvioidut kustannukset kunkin menetelmän osalta. Raporttimme tarkoituksena on havainnollistaa tutkimustyömme tuloksia ja luoda selvitys, jonka pohjalta eri menetelmien vertailu on yksinkertaista.

Tässä tutkimustyössä tarkemmassa teknisessä tarkastelussa olivat perinteiset konenäkömenetelmät, neuroverkkopohjaiset konenäkömenetelmät sekä vaihtoehtomenetelmät, kuten spektritekniikka. Lisäksi sivuamme näiden laitteistojen järjestelmä- ja ohjelmistovaatimuksina muun muassa logiikkaohjaimia ja neuroverkkoon pohjautuvaa deep learning -alustaa.

2 KONENÄKÖMENETELMÄT


Seuraavissa kappaleissa perehdytään erilaisiin konenäkömenetelmiin ja pyritään tarkastelemaan niiden soveltuvuutta kalalajien tunnistukseen.

2.1 Perinteinen 2D-konenäkö

Yksinkertaisimmillaan konenäkö perustuu kuvapisteiden kontrastierojen tulkitsemiseen. Esimerkiksi kappaleen reuna voidaan tunnistaa viereisten kuvapisteiden kontrastierona. Jotta kuvaa voidaan käyttää tunnistamisessa, tunnistettavan piirteen kontrastiero sekä kuvapisteiden määrä on oltava riittävän suurina. Erilaiset konenäköalgoritmit tulkitsevat näitä kontrastieroja, joiden perusteella voidaan kuvasta etsiä esimerkiksi tietynlaisia muotoja. (1.)

Perinteisellä 2D-konenäköllä pystytään suorittamaan erilaisia koodinlukuja, laadun tarkastuksia, paikoituksia, 2D-mittauksia ja luokitteluja. Kyseiset toimenpiteet ovat helposti suoritettavissa, kun tarkastettavalla kappaleella on esimerkiksi selkeät muodot ja värit, joiden avulla voidaan suorittaa tunnistus-, mittaus- tai paikoitusprosessit.

Kalalajeilla, joiden tunnistamista on tarkoitus tutkia, löytyy selkeitä eroja rakenteessa. Joten jos kuvasta tarkasteltaisiin jotakin pisteiden välistä suhdetta, esimerkiksi pituuden ja korkeuden välillä tai evien paikoitusten välillä, tai jotakin näiden yhdistelmää, saatettaisiin perinteisellä 2D-konenäköllä pystyä jollakin tarkkuudella luokittelemaan kyseiset kalalajit. Kuvassa (1) esimerkkipisteitä, joiden avulla luokittelu olisi ehkä mahdollista tehdä.



KUVA 1, Esimerkkipisteitä kalasta (1.)

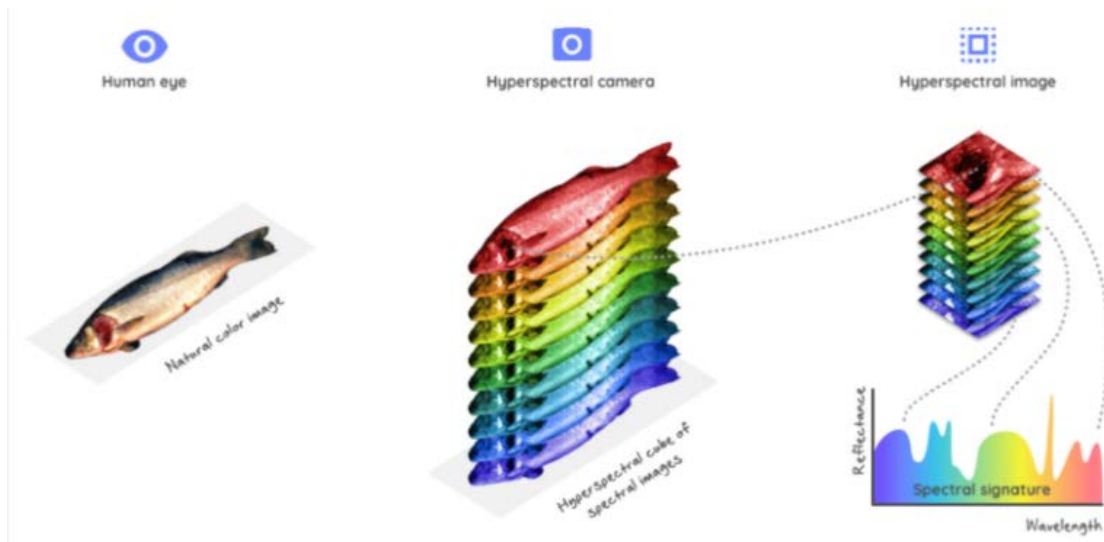
Kala on kuitenkin orgaaninen eliö, jolla ei välttämättä ole selkeää muotoa tai väriä, vaan kalan muoto, rakenne ja väri voivat vaihdella esimerkiksi vuodenajan, sukupuolen ja kalan iän mukaan. Ongelmaksi muodostuisi myös kalan asento, jonka muuttumisen myötä

jokin evä jäisi esimerkiksi piiloon ja konenäköjärjestelmä ei voisi muodostaa mittauspisteitä ja suorittaa vertailua.

2.2 Spektrikuvantaminen

Spektrikuvantamisen toiminta perustuu siihen, miten eri aallonpituuksilla lähetetty sähkömagneettinen säteily heijastuu spektrikameraan tutkittavasta kappaleesta. Spektrikuvantamisessa käytetään aallonpituuksia 700 nm - 12 μm , joilla saadaan aikaiseksi kulloiseenkin käyttötarkoitukseen soveltuva materiaalin läpäisy ja heijastuma. Tätä valon käyttäytymistä materiaalissa kutsutaan spektroskopiaksi. (2.)

Koska spektrikameralla pystytään tunnistamaan materiaalien kemialliset ominaisuudet, voidaan sillä kuvantaa esimerkiksi kalan tiheyttä, rasvapitoisuutta tai poimia tietoa laadullisista poikkeamista. Elintarviketeollisuudessa spektrikuvantamista on sovellettu menestyksekkäästi kalan laaduntarkkailuun, ja siinä käyttötarkoituksessa toiminta on jo vakiintunut.



KUVA 2, Kalan spektrikuvantaminen (3.)

Lajitunnistuksessa spektrikuvantamisen vaatimukset ovat kuitenkin hieman erilaiset kuin laadunvalvonnassa, koska eri kalalajien biologiset ominaisuudet ovat keskenään monin tavoin yhdenmukaiset. Elintarviketeollisuudessa kalan tunnistusasteen tulee olla suuri,


minkä vuoksi spektritekniikan soveltaminen tähän käyttötarkoitukseen on haastavaa. Kuitenkaan spektrikuvantaminen osana lajittelujärjestelmää laadun ja lisäinformaation saavuttamiseksi ei ole täysin poissuljettua.

2.3 Tekoälyn hyödyntäminen

Tekoälyn hyödyntäminen kalalajien tunnistamisessa perustuu datamäärän syöttämiseen valittuun tekoälypohjaiseen ratkaisuun. Työssä lähdimme keskittymään tutkimaan neuroverkkopohjaista tekoälyratkaisua. Työssä haluamme tunnistaa kaloja, jotka ovat orgaanisia kohteita ja yksilöillä on taipumus muuttua vesistön, iän, sukupuolen, vuodenajan ja tuoreuden mukaan. Neuroverkkopohjaisella menetelmällä on mahdollista koneen itse muodostaa tunnistustavat niin kuin ihminen muodostaa aivoissa hermoliitoksia, synapseja, oppiessa tunnistamaan kalalajeja tietyistä piirteistä. JAMK kuvaa kaloista videokuvaa eri asennoissa ja valaistuksissa, kuten käytännössäkin kalat ovat eri asennoissa linjalla. Videokuvasta päätetään kuvat irti, jolloin käsillä on iso määrä kuvia kaloista. Tämä kuvadatamäärä ja kuvissa esiintyvät kalalajit annetaan syötteenä oppivalle järjestelmälle, joka muodostaa synapsit, eli kalalajin tunnistamiseen vaadittavat piirteiden yhteydet itse. Kun järjestelmä on opetettu, se pystyy tietyllä varmuudella kertomaan, mikä laji kuvassa esiintyvä kala on. (4, 5.)

2.4 Neuroverkko kuvantunnistuksessa

Kvantunnistuksessa syvät neuroverkot (deep neural network, DNN) ovat muita koneoppimismenetelmiä parempia. Neuroverkot ovat tietojenkäsittelyjärjestelmiä, jotka voivat oppia tunnistamaan kaavoja kuvien välillä. Neuroverkot koostuvat kolmen tyyppisestä kerroksesta; Syötekerros (Input layer), piilokerros (Hidden layer), tulostekerros (Output layer). Kvantunnistamisessa syötekerros saa signaalin (kuvan), piilokerros käsittelee kuvan dataa ja tulostekerros ratkaisee tai ennustaa mitä se kuvassa näkee. Jokainen verkon kerros koostuu toisiinsa kytkeytyneistä solmukohdista (keinotekoisista hermosoluista), jotka suorittavat datan laskentatehtävän. Neuroverkosta tekee syvän se, että piilokerrosten määrä on tavallisen noin kolmen sijasta jopa satoja kerroksia.



KUVA 3 Neuroverkon havainnollistaminen (6.)

Opetettaessa syvää neuroverkkoa ei tarvitse tarkentaa mitä, esimerkiksi kalan kokoa tai väriä, opetusmalli huomioi. Syväoppiva järjestelmä muodostaa itse opetusdatasta piilo-kerrosten pisteet ja painokertoimet. Jokainen solmukohta opettelee edellisen tuottamalla ominaisuusjoukoilla, tällöin jokainen perättäinen kerros pystyy tunnistamaan yhä monimutkaisempia ja yksityiskohtaisempia piirteitä, joita kuva esittää. Mitä enemmän kerroksia verkossa, sitä paremmin se pystyy tulkitsemaan kuvaa.

Kuvan tunnistamisessa johtava menetelmä on konvoluutioneuroverkko (Convolution Neural Network, CNN). Erittäin yksinkertaistetusti konvoluutioverkko voitaisiin selittää: verkko tunnistaa laajempia kokonaisuuksia, konteksteineen, ei vain yksittäisiä pikseleitä, vaan myös niiden ympäristä. Esimerkiksi ihmisenkin silmä tunnistaa punaisen hatun kokonaisuudesta, ei yksittäisistä punaisista pikseleistä. Hatun erotamme vaikkapa punaisesta latauskaapelista sen muodon, liittimien ja ympäristön avulla. CNN-verkko pyrkii automaattisesti oppimaan tehokkaimmin syötteen tunnistetta vastaavat tunnusomaiset piirteet itse. Kalalajien tunnistamisessa neuroverkoista konvoluutioverkko tai sen kehitysmuoto olisi todennäköisesti toimivin. (7,8,9 s.58.)

3 VALAISTUSMENETELMÄT

Konenäköjärjestelmissä valaistuksen merkitys on oleellinen osa luotettavaa tunnistusprosessia. Tässä kappaleessa tullaan esittelemään yleisimmät valaistusmenetelmät ja niiden käyttötavat. Lopullisen valaistusmenetelmän valitseminen kalalajien tunnistuksen konenäköratkaisuun on vaikea arvioida ennen konseptitestausta, mutta tämä kappale esittelee ryhmämme tämänhetkistä näkemystä.

3.1 Taustavalaistus

Taustavalaistuksessa valonlähde asetetaan kuvannettavan kappaleen alle. Tällä menetelmällä saadaan aikaiseksi selkeät reunamuodot. Taustavalaistusta käytetään, kun halutaan mitata tutkittavien objektien pinta-aloja, reikien mittoja tai reunan epätasaisuuksia (10).

3.2 Suoravalaistus

Tässä valaistusmenetelmässä valo pyritään kohdistamaan mahdollisimman suoraan kappaleeseen nähden (11). Suorassa valaistuksessa käytetään yleensä useampaa valonlähdettä tai peilejä, jolloin varjot eivätkä virheheijastumat aiheuta häiriötä kameralle. Tällä menetelmällä saavutetaan terävä kuva kappaleen reunoista.

3.3 Tumma taustavalaistus

Tummassa taustavalaistuksessa valo ohjataan pienessä kulmassa kappaleen pintaan, jolloin kameralle korostuu kappaleen pinnan muodot (11). Tämä menetelmä soveltuu hyvin esimerkiksi pinnanlaadun ja pinnanlaadullisten poikkeamien tunnistamiseen.

3.4 Polarisoitu valaistus


Polarisoidussa valaistuksessa kameran eteen asennettu suodatin suodattaa valon heijastuneet komponentit. Tämä pienentää häiriövalon määrää kameralla, mutta mahdollistaa kappaleen voimakkaan valaisemisen. Tässä menetelmässä valaistuksen vaatimuksena on suuri valotehon määrä. (12.)

3.5 Värisuodatettu valaistus

Tällä valaistusmenetelmällä saadaan parannettua eri värien kontrastia harmaasävykuvissa. Esimerkiksi sinisellä suodattimella saadaan kontrastia parannettua punaisen ja vaalean sävyn välille. Värisuodattimilla voidaan myös suodattaa ympäristön valo pois, mikäli käytetään laser- tai led-valaisimia (11).

3.6 Epäsuora valaistus

Epäsuora valo heijastetaan heijastuspinnan kautta kohdepinnalle. Tällä saavutetaan tasainen valaistus ja varjojen määrä saadaan vähäiseksi. Epäsuoralla valaistuksella saavutetaan selkeä kokonaiskuva tutkittavasta objektista, jonka vuoksi sitä pidetään ensisijaisena valaistusratkaisuna kalalajien konenäöllisessä tunnistamisessa. Tällä valaistusmenetelmällä muun muassa suomujen aiheuttama karkeus ja kiiltävyys kalan pinnassa voidaan jättää huomiotta kalaa kuvattaessa.



KUVA 4, Valaistusratkaisuja konenäkömenetelmissä (13.)

4 VALMIIT RATKAISUT

Tässä osiossa kerromme mitä valmiita ratkaisuja on saatavilla ja miten ne soveltuvat tähän prosessiin. Valmiista ratkaisusta tutkittiin SICKin tarjontaa. SICKin älykamera suorittaa koko konenäköprosessin kuvan otosta, analysointiin ja toimenpiteisiin. Luultavasti myös muita älykameratoimittajia löytyy hintaluokan ollen sama.

Konenäön osaprosessit voidaan hajauttaa eri järjestelmille. Sitä vaihtoehtoa tutkittiin perehtymällä Beckhoffin automaatiojärjestelmään ja siihen liitettävään kameraan. Hajautettu järjestelmä on laitteiston osalta edullisempi, mutta se vaatii enemmän integrointityötä sekä ohjelmointiosaamista.

4.1 SICK

SICKiltä löytyy työhön soveltuva InspectorP62x 2D-konenäkökamera (Kuva 5). Kameran kuvantoisto/skannausnopeus on 50 Hz, joten se olisi riittävän nopea, vaikka oletettaisiin kalojen olevan pienempiä mahdollisia ja tulevan tunnistukseen maksimi kapasiteetilla. Lisäksi kamera tukee SICKin deep learning ympäristöä ja Dstudio palvelua. (14, Tuotevalikoima-> Teollinen-> kuvankäsittely-> 2D-konenäkö-> InspectorP62x.)



Kuva 5, InspectorP62x kamera (14.)

SICK:n tarjoama AppSpace Artificial Intelligence Deep Learning ympäristö on hyvin käytäjäystävällinen se ei edellytä käyttäjältä mitään perustietoja koneopetuksesta. Lisälaitteita tai ohjelmistoja ei tarvita pilvikoulutuksen ansiosta. (14, Tuotevalikoima-> SICK AppSpace-> SICK AppSpace Artificial Intelligence-> Deep Learning.)

Tekoälyn opetus tapahtuu SICKin DStudio verkkopalvelussa. DStudio avulla voidaan kouluttaa eri SICK-laitteille optimoituja neuroverkkoja. Koulutuksen eteneminen ja menestys esitetään havainnollisesti niin, että neuroverkko voidaan arvioida jo ennen se tuotavaa käyttöä. (14, Tuotevalikoima-> SICK AppSpace-> SICK AppSpace Artificial Intelligence-> Deep Learning.)

Hinta P62x sarjan kameralle, joka tukee Dstudiota on noin 8000 euroa. Kameran suorituskykyä voidaan tarvittaessa lisätä SIM1012-laitteella, jonka tehtävänä on kerätä, arkistoida ja arvioida tietoa. SIM1012-integraatiotuotteen hinta on noin 1500 euroa.

Kun mallikuvat on ladattu Dstudioon, siellä tehdään kuvien mukaan opetus. Opetusvaihe ei maksa mitään. Kustannuksia syntyy siinä vaiheessa, kun generoitu "koodi/opetus" katsotaan riittävän hyväksi eli tunnistus opetettujen kuvien mukaan toimii riittävällä varmuudella, ja koodi halutaan ladata kohdelaitteeseen. Tämä koodin alaslataus maksaa 750 euroa per kerta. Lisähintaa tulee myös tarvittavista lisätarvikkeista, kiinnikkeistä, kaapeleista, lisävalaistuksesta ja liitäntäbokseista. (15.)

SICKin tuotteita käyttäen kalalajien luokittelussa päästään todennäköisesti hyvään tulokseen noin 10 000 euron hinnalla. Hinta ei sisällä mahdollisia kuljettimia tai lajittelukoneita.

4.2 Beckhoff

Projektiryhmänä selvitimme Beckhoffin vaihtoehtoja kalan tunnistukseen. Tutkittiin heidän valikoimaansa ja löysimme tuotteen, joka voisi olla potentiaalinen vaihtoehto. Beckhoffin tarjoama tuote on nimeltään Neural Network Inference Engine. Tuote toimii saumattomasti yhdessä Twincat 3 -kehitysympäristön kanssa.

Ensi käsityksen mukaan tuotteeseen syötetään kuvia, joita prosessoidaan valmiissa neuroverkko työkaluissa. Teimme tutkimusta aiheesta ja totesimme että, tuotteen toiminta oli hieman monimutkaisempi ja vaati ulkoisia järjestelmiä. Vahvistuksen asiaan antoi Beckhoffin asiantuntia, kun keskustelimme sähköpostitse asiasta. (16.)

Projektiyhmämme otti yhteyttä yrityksen edustajaan ja kyselimme tuotteen soveltuvuudesta tarpeeseemme. Yrityksen tarjoamat tuotteet olivat rajoitetusti mahdollisia käyttää opetettavaan kuvantunnistukseen. Neuroverkko pohjainen TF3810 on Beckhoffin uutta tuotantoa ja tällä hetkellä tuote tukee ainoastaan Multi Perception -tyyppisiä neuroverkkoja, eikä vielä toistaiseksi kuvan tunnistuksessa yleisemmin käytettyjä konvoluutioverkkoja. (17.)

Kuvadata täytyy tallentaa taulukoksi, mikä rajoittaa sen sisältämää informaatio määrää MLP- verkon suorituskyvyn lisäksi. MLP- verkkoa voidaan suorittaa alle 1ms ajassa kymmeniä tuhansia neuroneita. Moniydin suoritus puuttuu, joten yhden ytimen suorituskyvyllä on väliä. (17.)

Beckhoffin TwinCAT3 järjestelmässä käytettävät työkalut ovat TFxxx TwinCAT Vision automaatio ohjelmointi sovellus ja liitännäisenä käytettävä TF3810 NN Inference Engine. Beckhoffilla ei ollut tarjota omaa kamera, mutta suosittelivat yhteensopivaa GigE -vision kameraa OEM:n valikoimasta. Beckhoffilta olisi saatavilla myös lisäosa, jolla voidaan mitata esimerkiksi kuljettimen virrankulutuksen ja momentin avulla kuljettimella kulkevan tavaran painoa erillisellä inputilla moottorinohjaus yksikön avulla. Massan tunnistus vaatii datan keräämistä etukäteen. (17.)

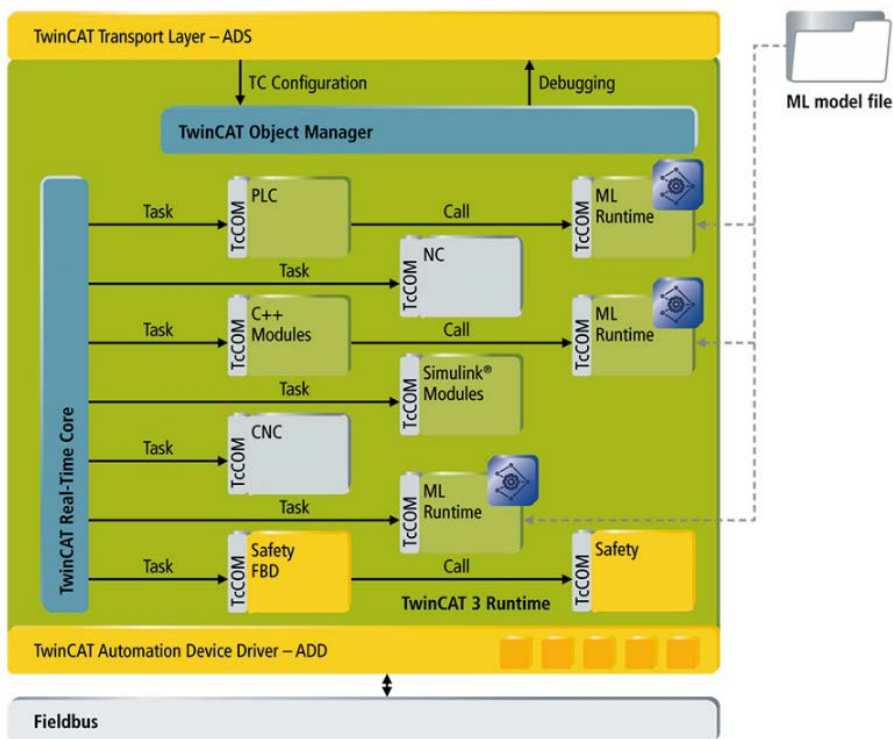
Ohjelmointi työkaluista yrityksen omia sovelluksia on mahdollista koekäyttää loputtomiin 7 päivän lisensseillä tutkimuskäytössä, joten se mahdollistaa tuotteeseen tutustumisen ennen lopullisen päätöksen tekemistä. Ohjelmistoihin on saatavilla myös konekohtaiset lisenssit. Toimittajalta on saatavissa erilaisia tietokoneita neuroverkkopohjaiseen työkentelyyn esimerkiksi CX5240 tai C6015. (17.)

Beckhoffin sovelluksiin ei kuulu omaa neuroverkon opetusta. Neuroverkon opetus toteutetaan kolmansien osapuolien työkaluilla. Yhteensopivia työkaluja ovat ilmaisista ohjelmista Python ja maksullisista Matlab. Beckhoffin yhteyshenkilön mukaan kumpikin sopivat käyttöön erinomaisesti, mutta Python pohjaiseen on helpompi löytää valmiita koodi esimerkkejä ja tarvittavaa materiaalia. Opetustyökaluilla muodostettu MLP-verkko täytyy muodostaa ONNX-muodossa, jotta TwinCAT tukee MLP-verkkoa ohjelman ajossa (runtime). (17.)

Suorituskyky vaatimuksien osalta Beckhoffin tarjoama järjestelmä toimii, kun minimipainoltaan 0,01 kg kaloja täytyy saada sekunnissa 0,28 kg. Yhden kalan tunnistamiseen on

aikaa 1/ 28 s, joka on noin 35 ms. Tämän pitäisi olla mahdollista heidän laitteillaan. Ehdottomana plussana heidän laitteissaan on synkroniassa TwinCAT-ohjelmalla ohjattu kuljetin, kamera ja tunnistus. Tällöin aikaa ei kulu ulkopuolisten järjestelmien kanssa kommunikointiin. Vision ohjelma osaa suorittaa myös mittauksia kuvista, joten koon tunnistus voitaisiin suorittaa pituus mittauksena. (17.)

Beckhoffin tuotteista hintatiedot jäivät vähäisiksi. Tietokone paketti on asiantuntijan arvon mukaan 1500 € luokkaa. Lisenssit maksavat kymmenistä satoihin euroihin per kone. Lähetimme sähköpostilla kyselyn vielä Beckhoffin asiakaspalveluun tarjouskyselyä.



Kuva 6, Neural Network Inference Engine (16.)

4.3 OEM

Oamkin yhteistyöverkostoon kuuluvalla oululaisella Probot Oy -yrityksellä on kokemusta ja toimituksia konenäköratkaisuista ja automaatiojärjestelmistä. Konsultoimme yrityksen toimitusjohtajaa Matti Tikanmäkeä aiheesta. Saimme vihjeen kysyä OEM:n tarjontaa ja otimme yhteyttä Development Manager Miikka Himankaan.

Valmista ratkaisua OEM:llä ei ole tarjota, mutta tarvittavat komponentit heiltä löytyisi. OEM:ltä painotettiin, että konenäköä määriteltäessä pyritään aina mahdollisimman tarkkoihin lähtötietoihin, jonka pohjalta menetelmä/komponentit valitaan lähtökohtaisesti. (18.)

Kalojen mittaamiseen suositeltiin vastavalo menetelmää. Tällä menetelmällä itse kohteen variaatio (väri, paksuus tms.) ei vaikuta järjestelmän kyvykkyyteen, vaan kappaleesta näkyisi aina sen silhuetti. Tässä etuna olisi, että silhuetin muotoa voisi käyttää myös itse lajiluokittelussa. (18.)

Jos kalan pituus- tai pinta-alatiedosta ei saisi luotettavaa kuvaa kalan koosta, kokolajittelu pitäisi suorittaa volyymin mittauksella. Tällöin tarvittaisiin 3D menetelmiä. 3D menetelmiä löytyy muutamia riippuen tarkkuus vaatimuksista ja linjan mekaanisesta toteutuksesta. Kokoluokan analysointi toteutettaisiin perinteisillä kiinteillä algoritmeilla. (18.)

OEM yhteyshenkilö suositteli hyvälaatuista 2D-värikuvaa neuroverkkoa käytettäessä. Komponenttien osalta tässä painotus valaistuksessa ja kameran hyvässä dynamiikassa. Perinteisestihän Suomessa olevat kalalajit ovat eri harmaan sävyjä, joten värin toiston täytyy olla hyvä. (18.)

Beckhoffin Twincat-ympäristöön kävisi GigE Vision -rajapintaan yhteensopiva kamera, jollaisesta pyydettiin tarjousta. OEM tarjosi tähän tehtävään hyvällä dynamiikalla ja herkkyydellä varustettua kameraa Basler aca1920-50gc ja optiikaksi M112FM12. Yhteishinta näille on reilu tuhat euroa (alv 0). (19.)

Tarjousta lähdettiin pyytämään diffuusiivista valoista heijastumien ja kuvan palamisen eliminoimiseksi. Valaistuksen osalta haastavaksi muodostui iso kuva-ala. OEM edustaja totesi, että diffuusit konenäköspeksit omaavat valot ovat kohtalaisen kalliita (n. 2000 €). Ehdotuksena tuli lähteä testaamaan paria diffuusiivaa viivavaloa kuten Sangelin valoja, jotka ovat CRI-arvoltaan hyviä eivätkä virtaohjattuna välky kameralle. Näitä on käytetty isojen alueiden valaisuun. 650 mm pitkä malli maksaisi noin 250 € (alv0). Näitä voisi laittaa esimerkiksi kaksi kappaletta kulmaan suhteessa kohteeseen. (19.)

5 YHTEENVETO

Tutkielmassa etsittiin vastauksia kysymyksiin, kuten millä laitteistolla kotimaisten kalalajien tunnistaminen onnistuisi, onko valmiita laitteistoja olemassa, ja minkä luokan kustannuksista on kyse. Epävarmuutta järjestelmän toteutettavuudesta aiheutti tutkittavan tuotteen orgaanisuus. Orgaanisuus tuo tunnistusprosessiin mukaan mahdollisuuden biologisiin poikkeavuuksiin, ja näin ollen laitteiston vaatimukset kasvavat huomattavasti verrattuna perinteisiin konenäkömenetelmiin.

Tutkielman edetessä käsiteltiin lukuisia konenäköön liittyviä aiheita, kuten kameralaitteistoja, neuroverkkoon liittyviä oppimisympäristöjä sekä valaistusmenetelmiä. Markkinoiden tarjonta neuroverkkoon pohjautuvan konenäköjärjestelmien osalta on vielä suppea, mutta eri valmistajilla on uusia vaihtoehtoratkaisuja kehitteillä.

Haasteena tutkielmassa oli olemassa olevan tutkimustiedon vähyys. Monet tutkimuksessa esitetyt ratkaisuehdotukset on esitetty ryhmän aikaisemman teoretietämyksen pohjalta. Käytännössä toimivat ratkaisut saavutetaan vasta konseptitestauksen avulla, mutta tämä tutkielma antaa alustavia ratkaisuehdotuksia käytännön toteutusta varten.

Tutkimuksen onnistumisen kannalta oli tärkeää, että eri yhteistyötahot olivat kiinnostuneita projektin toteutuksesta. Tutkielmassa esitelty lopullinen ratkaisuehdotus koostettiin yritysten esittämien ideoiden ja ryhmän jäsenten tekemän tutkimustyön pohjalta.

Kalalajien tunnistus konenäöllä neuroverkkoa hyödyntämällä tuntuisi olevan mahdollista, todellinen kyvykkyys selviää vain käytännön kokeilla. Laskennallisesti laitteiston kyky pitäisi riittää annettuihin suoritusvaatimuksiin.

LÄHTEET

1. Hornberg, A. 2006. Handbook of Machine Vision. Wiley-VCH.
2. Specim 2021. What is Hyperspectral Imaging? Saatavissa: <https://www.specim.fi/library/what-is-hyperspectral-imaging/>. Hakupäivä 15.2.2021.
3. MDPI 2020. Spectroscopic Techniques for Monitoring Thermal Treatments in Fish and Other Seafood. Saatavissa: <https://www.mdpi.com/2304-8158/9/6/767/htm>. Hakupäivä 15.2.2021.
4. Junttila J. 2021. Lehtori. Sähköpostiviesti 15.2.2021. OAMK. Konenäön hyödyntämisen tutkielman lisätietoja.
5. Moodle Kurssin TK00BP62-3005 Elektroniikka ja ohjelmointi. Anturitekniikan kurssimateriaali. Saatavissa: <https://moodle.oamk.fi/course/view.php?id=8958#section-2> Hakupäivä: 22.03.2020.
6. Singh Rana, Medium.com. Multi-layer Perceptron using Keras on MNIST dataset for Digit Classification. Saatavissa: <https://medium.com/analytics-vidhya/multi-layer-perceptron-using-keras-on-mnist-dataset-for-digit-classification-problem-relu-a276cbf05e97> Hakupäivä 22.03.2020.
7. Altexsoft, Blogipostaus. Image Recognition with Deep Neural Networks and its Use Cases. Saatavilla: <https://www.altexsoft.com/blog/image-recognition-neural-networks-use-cases/> Hakupäivä 22.03.2020.
8. Bonner Anne, towardsdatascience.com. The Complete Beginner's Guide to Deep Learning: Convolutional Neural Networks and Image Classification. Saatavilla: <https://towardsdatascience.com/wtf-is-image-classification-8e78a8235acb> Hakupäivä 22.03.2020.

9. Pietikäinen, Matti - Silvén, Olli 2019. TEKOÄLYN HAASTEET – KONEOP-
PIMISESTA JA KONENÄÖSTÄ TUNNETEKOÄLYYN. Konenäön ja sig-
naalianalyysin keskus, Oulun yliopisto. Saatavissa: [http://jultika.oulu.fi/Re-
cord/isbn978-952-62-2482-4](http://jultika.oulu.fi/Record/isbn978-952-62-2482-4) Hakupäivä 22.03.2020.
10. Honkala T. 2010. Opinnäytetyö. Saatavissa:
[https://www.theseus.fi/bitstream/handle/10024/15961/Toni_Hon-
kala.pdf?sequence=1&isAllowed=y](https://www.theseus.fi/bitstream/handle/10024/15961/Toni_Honkala.pdf?sequence=1&isAllowed=y). Hakupäivä 20.2.2021.
11. Jyrkkä J. 2018. Konenäön hyödyntäminen robotin ohjauksessa. Saata-
vissa: <http://jultika.oulu.fi/files/nbnfioulu-201805171821.pdf>. Hakupäivä
20.2021.
12. Vision Doctor. Inspecting with backlight illumination. Saatavissa:
[https://www.vision-doctor.com/en/illumination-techniques/backlight-illumi-
nation.html](https://www.vision-doctor.com/en/illumination-techniques/backlight-illumination.html). Hakupäivä 15.3.2021.
13. Vision System Design. Lighting and Illumination Choices. Saatavissa:
[https://www.vision-systems.com/knowledge-zone/article/14040172/lighting-
and-illumination-choices](https://www.vision-systems.com/knowledge-zone/article/14040172/lighting-and-illumination-choices). Hakupäivä 15.3.2021.
14. Sick. Saatavissa: www.sick.com. Hakupäivä 19.3.2021.
15. Sarviaho, V. 2021. Area Sales Manager. Sähköpostiviesti 19.03.2021.
SICK Oy.
16. Beckhoff 2021. TC3 Neural Network Inference Engine. Saatavissa:
[https://www.beckhoff.com/fi-fi/products/automation/twincat/tfxxx-twincat-3-
functions/tf3xxx-tc3-measurement/tf3810.html](https://www.beckhoff.com/fi-fi/products/automation/twincat/tfxxx-twincat-3-functions/tf3xxx-tc3-measurement/tf3810.html) Hakupäivä 15.2.2021.
17. Pammo, H. 2021. Support Engineer. Sähköpostiviesti 15.3.2021. Beckhoff
Automation Oy.
18. Himanka, M. Development Manager Machine Vision, Konenäkö. Sähkö-
postiviesti 11.3.2021. OEM Finland Oy
19. Himanka, M. Development Manager Machine Vision, Konenäkö. Sähkö-
postiviesti 23.3.2021. OEM Finland Oy