

**HEVOSEN HYVINVOINNIN SEURAAMINEN KONENÄÖLLÄ JA
ANALYSOINTI KONEOPPIMISEN AVULLA**



Ylemmän ammattikorkeakoulututkinnon opinnäytetyö

Vismäki, Älykkäät palvelut digitaalisessa ympäristössä

syksy 2021

Markku Kippola

TIIVISTELMÄ

Tietoisuus hevosen hyvinvoinnista ja hevosen kivun määrittämisestä on kasvanut viimeisen parinkymmenen vuoden aikana. Hevosen kipua on määritetty erilaisissa tutkimuksissa hoitotoimenpiteiden yhteydessä ja konkretisoitu hevosenomistajien ja eläinlääkärien hiljaista tietoa – ihmisten, jotka ovat opetelleet “lukemaan” hevosten ilmeitä, liikkeitä ja olemusta.

Tämän tutkimuksen tavoitteena oli tutkia voidaanko hevosen hyvinvointia seurata konenäön ja tekoälyn avulla. Tähän liittyi oleellisesti olemassa olevien kaupallisten sovellusten löytäminen. Tuotantoeläinten puolelta löytyi kaupallisia esimerkkejä ja paljon tutkimusta. Osa tuotantoeläinten sovelluksista sisälsi samantyyppisiä ominaisuuksia. Erona tuotantoeläimissä oli se että eläimiä käsiteltiin yleensä ryhmänä tai laumana ja sovellukset eivät samalla tavalla keskittyneet yksilöihin kuin oma ajatus on. Hevosiin liittyen kaupallisia ratkaisuja ei oikein löytynyt.

Tutkimuksessa selvisi mahdollisuudet käyttää olemassa olevaa teknologiaa ja mitä vaatimuksia hevosen hyvinvoinnin seuranta vaatii ja miten olemassa olevaa teknologiaa sovelletaan. Työssä myös määritettiin jatkotutkimusta ja mahdollisen ensimmäisen kaupallisen sovelluksen perusvaatimuksia.

Avainsanat Konenäkö, tekoäly, hyvinvointiteknologia

Sivut 57 sivua

Visamäki

Author Markku Kippola

Year 2021

Subject Monitoring horse welfare with machine vision and machine learning based analysis

Supervisors Jukka Pulkkinen

ABSTRACT

Awareness of horse welfare and the knowledge of horse pain has increased over the last twenty years. Horse pain has been determined in various studies during the treatment procedures and the tacit knowledge of horse owners and veterinarians has concretize how to “read” the expressions, movements and essence of horses.

The aim of this study was to find out how the welfare of a horse can be monitored using machine vision and artificial intelligence. This involved finding existing commercial applications. Commercial examples and a lot of research were found on the livestock farming. Some livestock applications contained similar features. The difference in farm animals was that the animals were usually treated as a group or herd and the applications did not focus on individuals in the same way as my idea. No commercial solutions were found for horses.

The study found out the possibilities of using existing technology and what requirements are required to monitor the welfare of the horse and how the existing technology is applied. Further research and basic requirements for a possible first commercial application were also defined in the work.

Keywords Machine vision, artificial intelligence, welfare technology

Pages 57 pages

Sisälllys

1	Johdanto	1
2	Tutkimuksen kuvaus ja menetelmät	2
2.1	Tavoite.....	2
2.2	Aiheen rajaus.....	2
2.3	Lupa kuvaamiseen.....	3
2.4	Tutkimuksen metodologia	3
2.4.1	Konstrukttiivinen tutkimusote.....	3
2.5	Tutkimuskysymys	4
2.6	Keskeisten käsitteiden määrittely.....	5
3	Teoreettinen viitekehys ja aiempi tutkimus.....	5
3.1	Hevosen hyvinvointi.....	6
3.2	Konenäkö	7
3.3	Tekoäly ja koneoppiminen	10
3.3.1	Mitä on tekoäly	11
3.3.2	Mitä on koneoppiminen.....	12
3.3.3	Syväoppiminen ja neuroverkot	12
3.4	Teknologiaa eläinten hyvinvoinnin seurannassa	13
3.4.1	Sikojen hyvinvoinnin seuranta	14
3.4.2	Lehmien hyvinvoinnin seuranta	17
3.4.3	Hevosten hyvinvoinnin seuranta.....	19
4	Hevosen hyvinvoinnin seuranta konenäöllä ja koneoppimisen avulla	20
4.1	Tavoite.....	20
4.2	Mitä	20
4.3	Mitä asioita konenäöllä tulisi pyrkiä etsimään?	26
5	Proof of concept ratkaisu hevosen hyvinvoinnin seurantaan.....	29
5.1	Konenäköjärjestelmän kokeilu.....	29
5.2	Konenäköjärjestelmän kokeilun tulokset	35
5.3	Haasteet kokeilussa.....	36
5.4	Haasteet konenäön ja tekoälyn käytössä	37
5.5	Suunnitelma jatkosta	39
5.5.1	Konenäkö ja tekoäly	39

5.5.2	Kamerajärjestelyt	40
5.5.3	Äänen hyödyntäminen	41
5.5.4	Tunnistaminen kauempaa	41
5.5.5	Tekoäly	41
5.5.6	Amazon Sagemaker kehitysympäristö	41
5.5.7	Valmiit datasetit	42
5.5.8	Tensorflow	44
5.5.9	OpenCV	45
5.5.10	PyTorch	45
5.6	Objektien tunnistaminen	45
5.6.1	Haar kaskadi	46
5.6.2	Yolo (You only look once)	48
6	Johtopäätökset ja pohdinta	50
	Lähteet	53

Kuvat, taulukot ja kaavat

Kuva 1.	Sian kasvojen tunnistus neuroverkkotekniikalla	15
Kuva 2.	Horse Grimace Pain Scale – kipuasteikko (Development of the Horse Grimace Scale (HGS))	21
Kuva 3.	Hikoileva hevonen (Holistic Horse)	23
Kuva 4.	Ähkyilevä hevonen katselee kylkiään (University of Pennsylvania, School of Veterinary Medicine)	23
Kuva 5.	Huulien rullaus (Saillet)	24
Kuva 6.	Kuopiva hevonen (The Horse)	24
Kuva 7.	Vatsaansa potkiva hevonen (Horse-Canada.com)	25
Kuva 8.	(Kippola, ilmakehä laitumesta)	26
Kuva 9.	(Kippola, Piehtaroiva hevonen)	27
Kuva 10.	(Kippola, Hevosia laitumella lisäruokittuna kuivaheinällä.)	28
Kuva 11.	(Kippola, Konenäköjärjestelmä)	29

Kuva 12. Datasetin muodostaminen Rekognitionilla	30
Kuva 13. AWS - kuvien merkitseminen.....	31
Kuva 14. Opetussetin muodostaminen	31
Kuva 15. Konenäön tunnistamat hevoset	32
Kuva 16. Riittämätön määrä kuvia opetusmateriaalia	32
Kuva 17. Vision Appster käyttöliittymä; konenäkö tunnistaa kupin. Kuva Markku Kippola	33
Kuva 18. Liikkeen laskeminen.....	34
Kuva 19. Infrapunalla kuvattu talli. Kuva Markku Kippola	35
Kuva 20. Talli normaalivalaistuksessa. Kuva Markku Kippola	36
Kuva 21. Arlo Go kamerakuvaa tallista.....	37
Kuva 22. Korostettu tunnistettava asia ja annettu sille tunniste:”korvat”	39
Kuva 23. (Kippola, Tallin pohjapiirustus kameroilla)	40
Kuva 24. Amazon Sagemaker käyttöliittymä.....	42
Kuva 25. Ontuvan hevosen tunnistamisen malli (Equine Gait Model) (ElectrifAI)	44
Kuva 26. Ominaisuudet.....	46
Kuva 27. Kohteiden tunnistus ja sijainti kuvassa (Science)	48
Kuva 28. Yolo: n periaate (You Only Look Once: Unified, Real-Time Object Detection)	49
Kuva 29. Yolo:n toimintaperiaate	50

1 Johdanto

Hevonen on arvokas omistajalleen. Ei pelkästään, että hevonen itsessään maksaa tuhansista kymmeneen tuhansiin euroihin, vaan myös hevosen ylläpitoon menee rahaa joka päivä. Hevonen on monelle tärkeä niin sosiaalisessa kuin harrastusmielessä. Hevonen on se kumppani, jonka kanssa harrastetaan yhdessä, olipa se sitten kilpailemista tai puiden ajoa metsästä.

Tänä päivänä eläinten hyvinvointi on noussut merkittäväksi asiaksi ja teknologiaa käytetään hyvinvoinnin määrittämiseen ja analysointiin laidasta laitaan. Olipa kyse sitten kalojen tunnistamisesta tekoälyn perusteella tai tekoälyn opettamisesta tunnistamaan villieläimiä niiden käytöksen seuraamiseksi.

Eläimen sairastuminen on myös vakava paikka. Hevosen hoito voi pahimmillaan maksaa kymmeniä tuhansia euroja isoja operaatioita tehtäessä. Eläimet eivät itse kerro ongelmistaan ja paras tapa löytää ongelmat mahdollisimman varhaisessa vaiheessa on eläimen käyttäytymisen havainnointi. Ihmisen ei kuitenkaan käytännössä ole mahdollista seurata koko ajan eläimen käyttäytymistä ja tässä on mahdollisuus valjastaa teknologia käyttöömmme.

Ajatus tästä opinnäytetyöstä syntyi marraskuisena aamuyönä, kun oma hevosemme oli ähkyyssä ja talutin sitä räntäsateessa saadakseni ähkyn laukeamaan eläinlääkärin myötävaikutuksella. Taluttaessani hevosta muistin keskustelun, jonka kävin 2000-luvun alussa Helsingin yliopistolla agroteknologian laitoksella Matti Pastellin kanssa lehmien ontumisen havainnoinnista. Pastell kertoi, miten erilaisia sorkkasairauksia havaitaan, jopa kaksi päivää ennen kuin ihminen havaitsee ontumisen.

Tuolta pohjalta mietin olisiko hevosilla mahdollista soveltaa samanlaista varhaista havainnointia teknologian avulla. Ensisijainen tehtävä olisi huomata muutokset ja toissijaisena opettaa tekoälylle mitä nuo muutokset tarkoittavat. Hevosen kipua on tutkittu paljon viimeisen kymmenen,

kahdenkymmenen vuoden aikana ja tuo tutkimus mahdollistaa ehkä myös muiden kivun indikaattorien käyttämisen.

2 Tutkimuksen kuvaus ja menetelmät

Tässä luvussa kuvataan tutkimusta, sen toteutusta ja rajoituksia.

2.1 Tavoite

Tämän opinnäytetyön tavoitteena on selvittää miten hevosen hyvinvointia voidaan seurata konenäön ja tekoälyn avulla. Tavoitteena on toteuttaa “proof of concept” eli osoittaa idea toteuttamiskelpoiseksi, että teknologian avulla voidaan saavuttaa riittävän hyviä tuloksia hevosen hyvinvoinnin arvioimiseksi tai poikkeaminen havaitsemiseksi hevosen käytöksessä.

Tavoitteen onnistumista eli työn tuloksellisuutta arvioidaan sen perusteella kuinka hyvin työ vastaa seuraaviin kysymyksiin:

1. Onko olemassa ratkaisua?
2. Onko olemassa soveltamiskelpoista teknologiaa, joka voidaan suoraan soveltaa?
3. Mitä vaatimuksia konenäön ja tekoälyn soveltamisesta seuraa?

2.2 Aiheen rajaus

Opinnäytetyön tavoite on selvittää miten hevosen hyvinvointia voitaisiin seurata konenäön ja tekoälyn avulla. Tämä työ rajoittuu olemassaoleviin ratkaisuihin, mahdolliseen soveltamiskelpoiseen teknologiaan ja ylipäättään mitä vaatimuksia konenäön ja tekoälyn käyttö aiheuttaa.

Konenäön osalta työ perustuu kokeellisuuteen ja olemassa olevien teknologiaratkaisujen testaamiseen miten ne soveltuvat ongelman ratkaisuun.

2.3 Lupa kuvaamiseen

Kaikki kokeilut ja kuvaaminen suoritetaan omassa tallissa. Kuvia ei julkaista, eikä kuvia käytetä muuhun kuin tutkimuskäyttöön.

2.4 Tutkimuksen metodologia

Opinnäytetyön aihe ja lähtökohdat määrittivät työn jo lähtökohdiltaan toiminnalliseksi opinnäytetyöksi, jonka toteutustapa on toimintatutkimus. Juuti & Puusa kertovat toimintatutkimuksen yhdistettävän laadulliseen tutkimusperinteeseen. "Leimallista ja omintakeista tälle lähestymistavalle on tutkimukset ja käytännön samanaikaisuus, eli toimintatutkimusta yhdistää käytäntöä ja teoriaa. Vaikka toimintatutkimus on kieltämättä käytännönläheistä myös siltä vaaditaan, että se käyttää tieteen menetelmiä systemaattisesti." Omalta kohdalta erityistä on ollut toimintatutkimukseen oleellisena liittyvä oppiminen. Tutkimuksen suorittaminen on ollut minulle väline oppia lisää, niin hevosen hyvinvoinnista, kuin konenäöstä ja tekoälystä. (Puusa, Juuti, & Aaltio, (2020))

2.4.1 Konstruktiivinen tutkimusote

Tutkimusongelmaa on lähestytty konstruktiiivisella tutkimusotteella. Lukka on määritellyt konstruktiiivisen tutkimusotteen:” Konstruktiivinen tutkimusote on innovatiivisia konstruktioita tuottava metodologia, jolla pyritään ratkaisemaan reaali maailman ongelmia ja tällä tavoin tuottamaan kontribuutioita sille tieteenalalle, jossa sitä sovelletaan.”

Konstruktiiivisen tutkimusotteen piirteitä ovat:

- keskittyy tosielämän ongelmiin, jotka koetaan käytännössä tarpeellisiksi ratkaista

- tuottaa innovatiivisen konstruktion, joka on tarkoitettu ratkaisemaan alkuperäinen tosielämän ongelma, – sisältää kehitetyn konstruktion toteuttamisyrittä, jolla testataan sen käytäntöön soveltuvuutta,
- merkitsee tutkijan ja käytännön edustajien hyvin läheistä tiimimäistä yhteistyötä, jossa odotetaan tapahtuvan kokemuksellista oppimista,
- on huolellisesti kytketty olemassa olevaan teoreettiseen tietämykseen, ja
- kiinnittää erityistä huomiota empiiristen löydösten reflektointiin takaisin teoriaan

Edellä kuvatun Lukan määrittelemien piirteiden mukaan olen lähtenyt ratkaisemaan ongelmaa, jonka katson tarpeelliseksi ratkaista. Toteuttanut konstruktioita, joilla on testattu käytäntöön soveltavuutta ja saavuttanut samalla kokemuksellista oppimista. Pyrkinyt kiinnittämään tämän tässä työssä teoreettiseen tietämykseen ja reflektointiin oppimani eli löydökset takaisin teoriaan. (Lukka, 2001)

Omasta mielestäni opinnäytetyö on noudatellut hyvin toimintatutkimuksen tieteellistä, tutkimuksen tekemisen, tiedon tuottamisen ja hankkimisen sekä teoriaa kehittävää tapaa. Työssä on pyritty yhdistämään toimintatutkimuksen tavalla käytäntö ja teoria ja mahdollistamaan jatkokehittäminen tieteelliseltä pohjalta. (Puusa, Juuti, & Aaltio, (2020))

2.5 Tutkimuskysymys

Tutkimusongelman määrittämiseksi tarvitaan tutkimuskysymys. Sen tarkoituksena on selkeyttää kysymyksen muotoon se mitä tutkimuksella halutaan tutkia tai tietää. (Saaranen-Kauppinen & Puusniekka, 2020)

Tämän opinnäytetyön tutkimuskysymyksenä on miten konenäköä ja tekoälyä voidaan hyödyntää hyvinvoinnin seurannassa.

2.6 Keskeisten käsitteiden määrittely

AI	Artificial Intelligence, tekoäly englanniksi
Konenäkö	Konenäkö tarkoittaa menetelmää, jossa kuvaa käsitellään ja analysoidaan ja sen perusteella voidaan tehdä päätöksiä. Tyypillisesti konenäköjärjestelmä koostuu kamerasta, tietokoneesta ja kameran signaalia tulkitsevasta ohjelmistosta.
Tekoäly	Tekoälyllä tarkoitetaan koneen kykyä käyttää perinteisesti ihmisen älyyn liitettyjä taitoja, kuten päättelyä, oppimista, suunnittelemista tai luomista.
Neuoverkko	Neuroverkoissa on haettu ideoita ihmisen aivojen toiminnasta ja miten aivot prosessoivat tietoa. Ne muistuttavatkin aivojen rakennetta mutta eivät ole aivojen kaltaiset ja eivät pysty lähellekään samaan kuin ihmisaivot.

3 Teorettinen viitekehys ja aiempi tutkimus

Tässä luvussa on käyty läpi sekä hevosen hyvinvointiin liittyvää taustaa sekä miten hevosen hyvinvointia määritellään. Luku sisältää myös teknologisen näkökulman eli taustaa konenäöstä, tekoälystä ja neuroverkoista sekä siitä miten teknologiaa on sovellettu eri eläinlajeihin. Pääpaino tässä on tuotantoeläimissä kuten naudoissa ja sioissa. Niiden osalta löytyy runsaasti hyvinvointiin ja teknologiaan keskittyvää tutkimusta. Hevosten osalta materiaali on suppeampi. Aihe on selkeästi kumminkin tutkijoita kiinnostava, koska aihetta on tutkittu nyt viime vuosina ja siitä löytyy useita tutkimuksia.

3.1 Hevosen hyvinvointi

Hevosen hyvinvointia voidaan määritellä monesta näkökulmasta. Eläinsuojelulaki tarjoaa lainsäädännön näkökulman eläimen hyvinvointiin. Eläinsuojelulaissa on määritelty yleisiä periaatteita seuraavasti:” Eläimiä on kohdeltava hyvin eikä niille saa aiheuttaa tarpeetonta kärsimystä. Tarpeettoman kivun ja tuskan tuottaminen eläimille on kielletty. Lisäksi eläintenpidossa on edistettävä eläinten terveyden ylläpitämistä sekä otettava huomioon eläinten fysiologiset tarpeet ja käyttäytymistarpeet.” ja ”Eläimen pitopaikan on oltava riittävän tilava, suojaava, valoisa, puhdas ja turvallinen sekä muutoinkin tarkoituksenmukainen ottaen huomioon kunkin eläinlajin tarpeet. Eläimen pitäminen tarpeetonta kärsimystä tuottavalla tavalla on kielletty.” sekä ”Hoidossa olevaa eläintä ei saa jättää hoidotta tai hylätä. Eläimen on saatava riittävästi sille sopivaa ravintoa, juotavaa ja muuta sen tarvitsemaa hoitoa. Eläimen sairastuessa sen on saatava asianmukaista hoitoa. Eläimen hyvinvointi ja olosuhteet on tarkistettava riittävän usein.” (Eläinsuojelulaki, 2021)

Hyvinvoinnin määritelmää täydentää Iso-Britannian eläinten hyvinvoinnista vastaavan Farm Animal Welfare Councilin määritelmä eläimen viidestä vapaudesta:

1. Freedom from hunger and thirst, by ready access to water and a diet to maintain health and vigour.
2. Freedom from discomfort, by providing an appropriate environment.
3. Freedom from pain, injury and disease, by prevention or rapid diagnosis and treatment.
4. Freedom to express normal behaviour, by providing sufficient space, proper facilities and appropriate company of the animal's own kind.
5. Freedom from fear and distress, by ensuring conditions and treatment, which avoid mental suffering.

(Farm Animal Welfare Committee (FAWC), 2021)

Lyhyesti suomennettuna nuo viisi vapautta ovat siis:

1. Vapaus janosta ja nälästä.
2. Vapaus epämukavuudesta
3. Vapaus kivusta, sairauksista ja vammoista.
4. Vapaus pelosta ja ahdistuksesta.
5. Vapaus toteuttaa lajinmukaista käyttäytymistä.

Lyhyesti kuvattuna eläin on hyvinvoiva kun se syö ja juo normaalisti, se elää eläimelle tyypillisissä olosuhteissa, se ei ole sairas ja kun se voi toteuttaa lajinmukaista käyttäytymistä.

3.2 Konenäkö

Professori Roy Davies Lontoon Yliopistosta kuvaa aisteista näkemistä tärkeimmäksi. Näkeminen aisteista tuottaa myös eniten dataa eli jatkuvan katselun tuottama data ylittää 10 megabittiä sekunnissa (mbit/s). Iso osa tuosta datasta on turhaa ja näköaivokuori käsittelee datan niin että, aivoille siitä päättyy vain pieni osa. Suuren datamäärän lisäksi, vaikuttavaa on helppous, millä tulkitsemme sitä mitä näemme. Tunnistamme helposti ja ilman ponnisteluita näkemämme asiat ja tuotamme tulkinnan näkemäämme sekunnin kymmenesosassa. Näkeminen on meille helppoa, siksi emme ole tietoisia kuinka monimutkaisesta kyvystä on kyse ja olemme käyttäneet miljoonia vuosia kyvyn hiomiseen nykyiseen muotoonsa. (Davies, 2012, p. 1)

Mitä on konenäkö?

Konenäköä käytetään usein teollisiin prosesseihin tarkoituksena vähentää kustannuksia lisäämällä tehokkuutta sekä kasvattamalla tuottavuutta ja vähentämään virheitä ja parantamaan laatua. Näin se voi myös korvata ammattitaitoisen työvoiman puuttumisen tai vapauttaa työntekijöitä vaarallisesta ja vaativasta työstä. (Smith, Smith, & Hansen, 2021, p. 1)

Davies määrittelee konenäön tutkimukseksi menetelmistä, tekniikoista ja laitteistoista joiden avulla voidaan rakentaa keinotekoisia näköjärjestelmiä käytännön sovelluksia varten. (Davies, 2012, p. 13)

Smith jne määritelmä on ehkä käytännönläheisempi ja määrittelee konenäön kuvan ymmärtämisen käytännön toteutuksena ja tarkemmin vielä konenäkötekniikoiksi, jotka auttavat ratkaisemaan käytännön teollisia ongelmia, joihin liittyy merkittävä kuvallinen osuus. (Smith, Smith, & Hansen, 2021, p. 1)

Kielitoimisto sanakirja määrittelee konenäön: ”Digitaaliseen televisiokameraan ja automaattiseen kuvankäsittelyyn perustuva havainnointijärjestelmä esimerkiksi robotin toimintona.”

(Kielitoimiston sanakirja - konenäkö, n.d.)

Smith jne myös yhdistää konenäköön tekoälyn (AI) ja kuvaa tätä yhdistämistä avioliitoksi konenäön ja koneoppimisen välillä. (Smith, Smith, & Hansen, 2021, p. 1)

Tuo määritelmä kuvaa hyvin myös omia tavoitteitani. Työssäni konenäön tavoitteena on saada tietokone ymmärtämään mitä kameran tai muun sensorin kuvaama näkymä sisältää ja käyttää tätä tietoa hyväksi eli tunnistaa hevosen eri liikkeitä, asentoja ja ilmeitä. Tuon perusteella tekoälyn tehtävänä on päätellä onko kyse normaalista käytöksestä vai jollain tavalla poikkeavasta käytöksestä.

Konenäön tyypilliset käyttökohteet

Konenäöllä on pitkä historia aina 30-luvulta lähtien, jolloin Electronic Sorting Machines käytti suodattimia ja valomonistimia ruuan lajittelukoneissa. Yritys on edelleen olemassa, tosin nykyään Japanilaisen Satake Groupin omistuksessa ja tarjoaa edelleen ruuan lajittelukoneita. Hiukan samanlaista teknologiaa käytettiin 40-luvulla myös kierrätettyjen uudelleen täytettävien pullojen tarkastusjärjestelmässä tarkastamaan, että pullot ovat puhtaita ja ehjiä ennen niiden uudelleen täyttöä. Huomionarvoista on että kaikki järjestelmät olivat täysin analogisia. Siitä huolimatta järjestelmiä oli käytössä yli 3000 kappaletta. Järjestelmässä oli mukana kaikki perusperiaatteet kappaleen tarkistamiseen eli pullon suun tarkistamiseen mahdollisten halkeamien varalta. (Zuech, 2000, pp. 7-8)

Tietokoneiden ja kamera- sekä valoteknologian parantuminen 80-luvulta lähtien ovat alentaneet kustannuksia ja tarjonneet uusia mahdollisuuksia teollisten konenäkötehtävien suorittamiseen. Tällaisia esimerkkejä ovat esimerkiksi esineiden koon ja sijainnin mittaaminen, pinnan laadun arviointi värin tai tekstuurin perusteella, vikojen tai epäpuhtauksien tunnistaminen, lajittelu tai komponenttien ja kokoonpanojen eheyden tarkistus sekä teollisuusrobottien ohjaaminen. Huomionarvoista on että lähes kaikissa näissä tapauksissa ympäristön tulee olla hyvin muuttumaton ja erityinen huomio on kohteen valaistuksella sekä sillä että kohteet ovat muuttumattomia ja ennalta määritellyissä paikoissa. Esimerkkinä esim. tuotantolinjan kuljettimella olevat esineet, jotka voidaan valaista hyvin ja sijoittaa kamera(t) sopiviin paikkoihin. Haasteeksi tulee tällaisissa tapauksissa mahdolliset muutokset. (Smith, Smith, & Hansen, 2021, pp. 3-4)

Konenäön haasteet

Ihmiselle näkeminen on yksi aisti, joka on kehittynyt miljoonien vuosien aikana ja on ollut elintärkeää selviytymisen kannalta. Erityisen hyviä olemme havaitsemaan muutoksia ja liikettä sekä luokittelemaan näkemämme samantien. Pystymme myös vaivattomasti päättelemään pienistäkin asioista kokonaisuuksia ja osittainekin informaatio, kuten vaikka se että näemme koiran pään nurkan takaa assosioi mielikuvan kokonaisesta koirasta ja tunnistamme sen pelkän pään perusteella koiraksi.

Perinteisesti kuvan automaattinen tulkinta on hyvin vaativaa. Kuva sisältää paljon informaatiota ja sen käsittely vaatii laskentatehoa. Perinteinen konenäkö perustuu kuvanoton ja analysoinnin kannalta vaiheisiin, jotka voidaan jakaa viiteen ydintoimintaan: 1) kuvan ottaminen 2) kuvan esikäsittely 3) segmentointi 4) ominaisuuksien erottaminen 5) luokittelu tai tulkinta. Kuvan ottamiseen liittyy normaalisti ympäristön vakioiminen kuten kohteen asemointi, kameran ja linssin valinta sekä valaistuksen suunnittelu. Perinteisesti tämä on tärkeä vaihe, koska se voi vaikuttaa voimakkaasti seuraavien vaiheiden kustannuksiin, tehokkuuteen ja luotettavuuteen. (Smith, Smith, & Hansen, 2021, p. 4)

3.3 Tekoäly ja koneoppiminen

Tekoäly on ollut viimeisen kymmenen vuoden aikana kovassa nosteessa. Nosteen on mahdollistanut mm. tietokoneiden prosessoreiden tehon kasvu, joka on helpottanut tekoälysovellusten kehittämistä. Viimeaikaisesta nosteesta huolimatta tekoälyn juuret ovat viisikymmentäluvulla ja tekoälykäsitteen isänä pidetään yhdysvaltalaista Stanfordin yliopiston tietojenkäsittelytieteen professoria John McCarthy (1927-2011). Vuonna 1956 hän esitteli termin *artificial intelligence* Dartmouth Collegen kesäseminaarissa. Tapahtuman järjestäjät olivat hiukan aikaansa edellä ilmoittaessaan seminaarin rahoitushakemuksessa, että kymmenen tutkijan ryhmä voisi kahdessa kuukaudessa ratkaista luonnollisen kielen oppimiseen, käsitteiden ja abstraktioiden muodostamiseen liittyvät ongelmat ja käsitellä niitä tekoälyohjelmilla. (Siukonen & Neittaanmäki, 2019)

Käytännössä meni kumminkin yli viisikymmentä vuotta ennen kuin ensimmäiset jollain tavalla luonnollista kieltä oppivat tekoälysovellukset toteutettiin. Esimerkkinä tällaisista voidaan käyttää erilaisia chattibotteja. Teknologyayhtiö Oracle antaa chattibotille määritelmän:” At the most basic level, a chatbot is a computer program that simulates and processes human conversation (either written or spoken), allowing humans to interact with digital devices as if they were communicating with a real person. Chatbots can be as simple as rudimentary programs that answer a simple query with a single-line response, or as sophisticated as digital assistants that learn and evolve to deliver increasing levels of personalization as they gather and process information.” (Oracle, n.d.)

Lyhyesti suomennettuna Oraclen mukaan chatbot on tietokoneohjelma, jolla ihmiset voivat olla vuorovaikutuksessa digitaalisten laitteiden kanssa aivan kuin he kommunikoisivat todellisen henkilön kanssa. Chatbotit voivat olla hyvin alkeellisia, jotka vastaavat yksinkertaiseen kysymykseen yksirivisellä vastauksella tai ne voivat olla kehittyneitä kuten digitaaliset avustajat, jotka oppivat ja kehittyvät tarjoamaan yhä enemmän personointia, kun ne keräävät ja käsittelevät tietoa.

Englanninkielellä tekoälystä käytetään usein lyhennettä AI eli Artificial Intelligence. Sama termi on ollut myös Steven Spielbergin tieteiselokuvan nimenä:” A.I.: Artificial Intelligence”, jossa Spielberg

on päässyt elokuvan keinoin käsitellyt luonnollisen älyä ja tekoälyä. Elokuvasa kerrotaan robotista, jolla on inhimillisiä piirteitä kuten tunteet. (Wikipedia, A.I. Artificial Intelligence, n.d.) Tieteiskirjallisuus onkin osasyllisenä tekoäly-käsitteen epämääräisyyteen liittämällä siihen vaikeita, hankalasti toteutettavia asioita kuten tunteet.

Koneoppiminen on tällä hetkellä tekoälyn yksi käytetyimmistä osa-alueista. Koneoppiminen (Machine Learning) perustuu siihen että järjestelmä oppii datasta sen ohjelmoinnin sijasta. Koneoppimisessa järjestelmä opetetaan jollain datalla ja järjestelmä oppii datasta. Järjestelmän käsitellessä myöhemmin uutta dataa se käsittelee aikaisemman oppimisen perusteella ja tunnistaa datasta sen perusteella haluttuja asioita. (IBM, n.d.) Koneoppimiseen liittyy ongelmia eli järjestelmä seuraa sille opetettua logiikkaa ja oppiminen on juuri niin hyvää kuin opettamiseen käytetty materiaali on. Tästä hyvänä esimerkkinä on Microsoftin 2016 julkaisema Tay chatbot, jonka Twitter-käyttäjät opettivat rassistiseksi, seksistiseksi ja lausumaan loukkaavia kommentteja. (The Verge, n.d.)

3.3.1 Mitä on tekoäly

Usein tekoälyn yhteydessä törmää lyhennykseen AI. AI tulee tekoälyn englanninkielisestä nimityksestä Artificial Intelligence. Edellä jo todettiin että käsitteenä tekoäly on epämääräinen ja siihen liitetään myös käsitteitä kuten keinoäly, koneäly, koneoppiminen ja syväoppiminen. Käsitteiden määrä kertoo myös ettei ole olemassa vain yhtä tekoälyteknologiaa, vaan olemassa on erilaisia menetelmiä ja tekniikoita riippuen mihin tarkoitukseen tekoälyteknologiaa ollaan hakemassa. Pohjimmiltaan tekoälyssä on kuitenkin kyse ohjelmoinnista, matematiikasta ja tilastotieteestä. (Kananen & Puolitaival, 2019, p. 27)

Tekoäly on ollut viimeisen kymmenen vuoden aikana kovassa nosteessa. Nosteen on mahdollistanut mm. tietokoneiden prosessoreiden tehon kasvu, joka on helpottanut tekoälysovellusten kehittämistä. Wikipedian määritelmän mukaan tekoäly on: ”Tekoäly eli keinoäly on tietokone tai tietokoneohjelma, joka kykenee tekemään älykkäinä pidettäviä toimintoja.” (Wikipedia, n.d.)

Toimittaja Dave Gershgorin (s. 1992) tiivisti näkemyksensä 10, syyskuuta 2017 Quartz-lehdessä "Tekoäly on ohjelmisto tai tietokoneohjelma, jossa on oppimismekanismi. Se käyttää oppimaansa tietoa päätöksen tekemiseksi uudessa tilanteessa ihmisten tavoin. Ohjelmistoa suunnittelevat tutkijat pyrkivät kirjoittamaan koodin, joka osaa lukea kuvia, tekstiä, videota tai ääntä ja oppia siitä jotain. Kun kone on oppinut, sen tietämystä voidaan hyödyntää muualla." (Siukonen & Neittaanmäki, 2019)

3.3.2 Mitä on koneoppiminen

Wikipedian määriteltä koneoppimiselle on: "Koneoppiminen on tekoälyn osa-alue, jonka tarkoituksena on saada ohjelmisto toimimaan entistä paremmin pohjatiedon ja mahdollisen käyttäjän toiminnan perusteella. Koneoppimisessa ohjelmistolle ei ole välttämättä määritetty toimintamenetelmää (algoritmia) jokaista tilannetta varten, vaan kone oppii itsenäisesti päätyämään haluttuun lopputulokseen." (Wikipedia, Koneoppiminen, n.d.)

Koneoppimisen juuret ovat 1950- ja 60-luvuilla ja perustuvat pitkälti matematiikkaan ja tilastotieteeseen. Koneoppimisen algoritmit tarvitsevat toimiakseen paljon dataa mutta datan määrän kasvattaminen ei paranna niiden suorituskykyä toisin kuin neuroverkkojen tapauksessa.

Koneoppiminen voidaan jakaa kahteen pääluokkaan eli luokittelumalleihin ja määrämalleihin. Luokittelumalli ennustaa jonkin tapahtuman todennäköisyyttä. Määrämalli ennustaa jonkin asian suuruusluokkaa, kuten määrää tai ajan pituutta. (Kananen & Puolitaival, 2019, p. 109)

3.3.3 Syväoppiminen ja neuroverkot

Syväoppiminen on viime aikoina kehittynyt nopeasti. Yksinkertaisten syväoppiminen tarkoittaa neuroverkkoja. Tämä mahdollistaa tekoälyn kognitiiviset ominaisuudet, kuten kuvan ja äänen tunnistuksen. Neuroverkoissa on haettu ideoita ihmisen aivojen toiminnasta ja miten aivot prosessoivat tietoa. Ne muistuttavatkin aivojen rakennetta, mutta eivät ole aivojen kaltaiset ja eivät pysty lähellekään samaan kuin ihmisäivot. Neuroverkkojen käytön kasvun on mahdollistanut

se, että dataa on paljon saatavilla ja sen tallentaminen on edullista, laskentateho on kasvanut samaan tapaan tallennustilan kanssa sekä matemaattiset ideat osataan toteuttaa käytännössä tehokkaalla tavalla. (Kananen & Puolitaival, 2019, p. 127)

Tämän työn taustalla on ajatus nimenomaan syväoppimisen hyödyntämisestä. Syväoppiminen soveltuu erinomaisesti siihen että kuvasta voidaan havainnoida, paikantaa ja luokitella objekteja ja sen perusteella hakea poikkeamia. Joissain tapauksissa syväoppimisen avulla olisi mahdollista myös ennustaa sairastumista oireiden perusteella.

3.4 Teknologiaa eläinten hyvinvoinnin seurannassa

Konenäköä ja tekoälyä on käytetty teollisuudessa jo pitkään. Sovelluksia löytyy myös elintarviketuotannosta mutta alkutuotannon puolella kaupalliset sovellukset ovat harvassa. (Fernandes, Dórea, & Rosa, 2020)

Eläinten hyvinvointi on osa nykyaikaista eläinten kasvatusta. Tätä nykyaikaista kasvatusta kuvataan englannin kielellä: ”precision livestock farming” (PLF), joka voidaan suomentaa nykYTEKNOLOGIAN mahdollistamaksi yksilöllistetyksi tuotantoeläinten kasvatukseksi. Siinä optimoidaan kasvatuksen prosesseja hyödyntäen teknologiaa tutkimaan ja tulkitsemaan niin fyysisiä kuin käyttäytymistä koskevia muutoksia jatkuvasti reaaliajassa. (Gómez, et al., 2021, p. 1)

Alkutuotantoon liittyy myös muita tekijöitä, kuten globaalisti kasvava väestö, viljelyyn liittyvät ympäristönäkökulmat, terveysvaikutukset ja eläinten hyvinvointi. Digitalisaatio helpottaa näiden tekijöiden hallintaa ja saavuttamista. PLF mahdollistavat prosessitekniikan periaatteiden käytön automatisoida karjan kasvatusta mahdollistaen viljelijöille tarkkailla suurten eläinmäärien terveyttä ja hyvinvointia huomioiden yksittäiset eläimet ja puuttua ongelmiin jo ennnekuin ne näkyvät. Esimerkkeinä voidaan käyttää lehmien käyttäytymisen tarkkailua, äänien havainnointia sikojen huudoista tai nautojen tiineyden havainnointia ruumiin lämmön vaihteluista. (Neethirajan & Kemp, 2021, pp. 1-2)

3.4.1 Sikojen hyvinvoinnin seuranta

Tieto sikojen hyvinvoinnista on tärkeää niin sikatilalliselle kuin kuluttajille. Sikatilalliselle heikko terveys tai ongelmat käyttäytymisessä, kuten hännänpurenta voivat pienentää sikojen kasvua. Sairaudet ja vammat vaativat antibioottien käyttöä. Kuluttajilla eläinten hyvinvointi on osa tuotteen laatua ja lihasta ollaan valmiita maksamaan enemmän.

Eläinten hyvinvoinnin arviointi ihmistyönä vaatii aikaa ja vaivaa. Nykyisissä hyvinvoinnin arviointimenetelmissä on myös puutteita. Niistä puuttuu eläinperäisiä indikaattoreita ja asioita tarkastellaan tilatasolla, ei yksittäisen eläimen näkökulmasta. Ne myös perustuvat laajasti ihmisen havainnointiin, jolloin arviot ovat subjektiivisia ja havainnoijasta riippuvia.

Teknologian käyttö tarkkailuun ja tuotantoprosessien optimointiin vähentää ihmistyön määrää. Tämä digitalisaation mahdollistama yksilöllistetty tuotantoeläinten kasvatus eli PLF tarjoaa sikatilalliselle työkalun suoraan ja jatkuvaan eläinten ja niiden olosuhteiden tarkkailuun ja helpottaa päätöksentekoa tarjoamalla työkaluja karjanhallintaan.

Sikojen käyttäytymisen ja olosuhteiden tarkkailuun on käytössä erilaisia antureita esim. kiihtyvyyssantureita, mikrofoneja ja kameroita. PLF voi tuottaa lisäarvoa hyvinvoinnin seuraamiseen mahdollistamalla yksilön tai kasvatusryhmän seuraamisen ilman stressaavia toimenpiteitä, kuten mahdollistamalla ruhon painon arvioinnin käyttämällä videokameroita ilman aikaavievää manuaalista punnitusta. Reaaliaikainen seuranta mahdollistaa aikaisten varoitusmerkkien huomaamisen hyvinvointiongelmien estämiseksi. (Gómez, et al., 2021, pp. 1-2)

Sikojen tunnistaminen

Sikojen kuvallinen tunnistaminen ratkaisee monia ongelmia. Se tarjoaa mahdollisuuden yksilön seurantaan ilman muita apuvälineitä. Tyypillisin tapa tunnistamiseen on ollut RFID-tagien (Radio Frequency IDentification) käyttö lävistämällä ne sikojen korviin. Niihin liittyy ongelmia, kuten lyhyt luenta- eli tunnistamisetäisyys (max 120cm) sekä tuotantorakennusten rakenteiden vaikutus

lukulaitteiden toimintaan niin etteivät laitteet toimi välttämättä ollenkaan. (Mark F. Hansen, 2018)

Manchesterin ja Cranfieldin yliopiston tutkimuksissa tutkittiin sikojen tunnistamista kasvoista eli periaatteessa samaa teknologiaa, jota on sovellettu ihmisten kasvojen tunnistamiseen lähes viiden vuosikymmenen ajan. Manchesterin yliopisto saavutti 96,7% tarkkuuden käyttämällä neuroverkkotekniikkaa. Cranfieldin yliopiston tutkimuksessa Saavutettiin yli 83% tarkkuus. (Mark F. Hansen, 2018) (Mathieu, et al., 2020)

Kuva 1. Sian kasvojen tunnistus neuroverkkotekniikalla



Cranfieldin yliopisto käytti Viola-Jones kasvojen tunnistustekniikkaa, joka tunnetaan paremmin nimellä Haar Cascades luokittelija. Kyseessä on tekoälyn ohjattu oppiminen, jossa tekoälyä opetetaan näyttämällä positiivisia eli haluttuja, etsittyjä kuvia sekä negatiivisia eli ei-toivottuja kuvia näyttämällä. (Behera, 2020)

Molempien tutkimusten perusteella sika on tunnistettavissa erittäin hyvällä tarkkuudella kasvoista.

Käyttäytyminen

Sika ei pysty kertomaan onko sillä kipuja tai tunteeko se olonsa huonoksi. Harjaantunut eläinten käsittelijä, kuten eläinlääkäri pystyy havainnoimaan eläimen olemuksen ja käyttäytymisen perusteella mahdollisia ongelmia ja kliinisellä tutkimuksella varmistamaan havainnot.

Aktiivisuutta voidaan seurata antureilla kuten kamera, kiihtyvyyssanturi, valosähköiset anturit, lämpökamera ja RFID-tagit. Näillä voidaan seurata käyttäytymisestä piirteitä kuten yleinen liikeaktiivisuus (aktiivinen, passiivinen), kävely (askeleiden määrä), seuranta (sijainti tai eläinten määrä sijainnissa), asento ja asennon muutokset (makaaminen, seisominen, istuminen) sekä yleinen liike suhteessa lämpötilaan. Yleisesti asennon tai asennon muutoksien seurannassa käytetään kameraa.

Stressikäyttäytymistä kuten hännänpurentaa voitiin ennustaa kameroiden perustella, jolloin indikaattorina oli eläinten levottomuus. Myös vesipisteiden käyttötaajuutta ja ympäristön lämpötilaa seuraamalla voitiin ennustaa hännän puremisen puhkeamista. Kuva-analyysiä käytettiin liikkumisen seurantaan ja eläinten paikantamiseen. Sen perusteella voitiin seurata kävelyä, juoksua, tutkimista, leikkimistä, hoivaamista, ruokkimista, virtsaamista ja selkään nousemista.

Syöminen ja juominen ovat eläimen perustarpeita. Piirteitä joita voidaan seurata ovat: rehun saanti, syömisen ja juomisen tiheys ja kesto, stressi nälästä tai janosta sekä hoito- ja imetyssä käyttäytyminen. Hoitokäyttäytymiseen voidaan käyttää kameroita. Janoon ja nälkään liittyvää stressiä äänen perusteella mikrofoneilla ja ja seuraamalla ihon lämpötilaa lämpökameroilla. Rehun saantia sekä juomista voidaan seurata RFID:n avulla automaattisessa rehun syötössä ja juotossa.

Sioilla teknologiaa on käytetty terveyden seurantaan. Terveystien liittyen on teknologialla tunnistettu ontumista, kynsivaurioita, afrikkalaiseen sikaruttoon liittyviä sairauden merkkien havaitsemista (aktiivisuuden väheneminen), influenssa A (kuume), hengityselinsairauksia, ripulia sekä yleisiä terveysongelmia. (Gómez, et al., 2021, pp. 8-11)

Tämän työn kannalta mielenkiintoinen on afrikkalaisen sikaruton (ASF) käytetty menetelmä seurata sikojen aktiivisuutta. Afrikkalainen sikarutto on sikojen verenvuotokuumetauti, johon ei ole hoitokeinoa tai rokotetta. (Ruokavirasto, 2021)

Infektiotautien varhainen havaitseminen voi pienentää sekä eläinten terveyteen että tilallisen talouteen liittyviä vaikutuksia. Madridin yliopistossa (Universidad Complutense de Madrid) tehdyssä tutkimuksessa osoitettiin sairauden vaikutus eläinten aktiivisuuteen että sen havainnointi hyödyntäen eläinten videointia ja videointidataa analysoimalla. Tutkimuksen mielenkiintoisimpana havaintona voidaan pitää sitä että päivittäinen liike väheni tartunnan saaneilla eläimillä noin 10% ennenkuin tautia voitiin havaita kliinisillä oireilla. (Fernández-Carrión, et al., 2017)

3.4.2 Lehmien hyvinvoinnin seuranta

Luonnonvarakeskuksen julkaisussa kartoitettiin kaupallistettuja PLF teknologioita. Markkinoilta löydettiin 129 erilaista myynnissä olevaa teknologiaa eläinten hyvinvoinnin tarkkailuun. Kuluttajien mielenkiinto eläinten hyvinvointiin on kasvanut ja kuluttajat ovat valmiita maksamaan enemmän maidosta, joka on tuotettu luomuna, ympäristöystävällisesti tai eläinten hyvinvointi keskimääräistä paremmin huomioiden. Kuluttajille tämä näkyy eläinten hyvinvoinnin paremmin huomioivien meijerituotteiden merkinnöistä. Euroopassa tällainen on Welfare Quality[®] (WQ[®])-sertifikaatti. (Gómez, et al., 2021)

Jalasjärveläinen Juustoportti hyväksyttiin Euroopan ensimmäiseksi Welfare Quality -sertifioiduksi meijeriksi. Juustoportti käyttää WQ[®]-sertifikaattia vapaan lehmän tuotteissaan. (KMVET, 2018)

Eläinten hyvinvoinnin mittaristossa on kuitenkin epätarkkuuksia: 1) niitä sovelletaan vain ryhmätasolla, 2) eläinten hyvinvoinnin seuranta ei ole jatkuvaa 3) arviot perustuvat ihmisten subjektiivisiin havaintoihin. Näitä voidaan ainakin osin ratkaista yksilöllistetyllä tuotantoeläinten kasvatuksella (PLF). Äkilliset muutokset eläinten aktiivisuudessa, ruokinnassa ja juomisessa, fyysisessä tilassa ja terveydessä voidaan havaita antureilla.

Konenäkö on lehmien hyvinvoinnin seuraamisessa varsin käytetty teknologia.

Luonnonvarakeskuksen julkaisussa 129 teknologiasta 10 oli konenäköön perustuvia eli lähes 8 prosenttia perustui konenäköön. (Gómez, et al., 2021, pp. 2-4)

Arla Iris

Arla Iris on Arla Oy:n Yhden tilan-tuoteperhettä varten kehitetty teköälysovellus lehmien hyvinvoinnin seurantaan, jonka avulla poikkeamat voidaan havaita heti ja niihin voidaan puuttua tilanteen korjaamiseksi. Yhden tilan maidon tarkoituksena on lisätä maidon tuotannon läpinäkyvyyttä kuluttajille. Arla Iriksen on toteuttanut teknologiayhtiö Empirica Finland Oy.

Arla Iris yhdistää eri tietolähteitä kehittyneelle teköäly-algoritmille, joka tarkkailee ja analysoi tietojen perusteella eläinten hyvinvointia. Eläinten hyvinvoinnin asiantuntijoiden ja kuluttajien kanssa Arla määrittä eläinten hyvinvoinnin kannalta merkitykselliset tekijät ja niistä valittiin ne, jotka soveltuivat automaattisesti mitattavaksi navetan tyyppisessä haastavassa ympäristössä.

Arla Iriksen mittaamat ominaisuudet:

- Laiduntaminen ulkona
- Makuumukavuus
- Arjen sujuvuus
- Lypsyllä käynti
- Elintila
- Terveysthuolto
- Ravinto
- Vasikoiden hoito

Konenäön toteutukseen vaikuttivat myös navetan vaihtelevat olosuhteet, kuten pöly ja valon määrän vaihtelu sekä rakenteet kuten putket ja verkkoyhteyksien kuuluvuus. Heikkojen yhteyksien

vuoksi kuvat analysoidaan kameroissa tiedonsiirtomäärien laskemiseksi ja pelkkä analyysin tulos lähetetään eteenpäin. (Empirica Oy, 2021)

3.4.3 Hevosten hyvinvoinnin seuranta

Hevosen hyvinvoinnin seurannassa on tärkeää pystyä tunnistamaan hevosen kipu. Hevosen kivun tunnistaminen on kuitenkin haastavaa, koska hevonen on saaliseläin ja pyrkii kaikin keinoin peittämään kivun. Asiaan vaikuttavat lisäksi hevosen rotu, temperamentti, hevosen aiemmat kokemukset kivusta ja tilanteista, suhde hoitajaan jne. Alkuperäisrodut eivät näytä aina kipuaan yhtä helposti kuin pidemmälle jalostetut hevoset. Lisäksi asiaan vaikuttaa onko hevonen koulutettu ja tottunut käsittelyyn vai kouluttamaton ja käsittelemätön. Jokaisen hevosen kipukäytös on yksilöllistä, joka tekee haastavammaksi sen havaitsemisen.

Kipukäyttäytyminen

Kipu aiheuttaa hevoselle erilaisia fyysisiä merkkejä kuten noussut syke, kiihtynyt hengitys sekä hidastunut ruuansulatus. Muita merkkejä voivat olla stressihormonien nouse ja verenpaineen nousu. Hevosella kipu vaikuttaa samaan tapaan kuin ihmisellä unen laatuun ja unen laatu heikkenee. Toisin kuin ihminen hevonen voi nukkua seisaltaan mutta sen on päästävä makuulle nukkumaan syvää unta. Voimakas kipu on yleensä helppo huomata. Hevonen aristaa jotain kohtaa selvästi, kuten esimerkiksi ontumissa tai katselee kipukohtaansa esimerkiksi ähkyssä kylkeään. Kivusta voi kertoa myös muu muuttunut käytös tai tavat kuten jalan lepuuttaminen, seisoma-asennon jatkuva muuttaminen, varovainen liike, lyhentynyt askel, jäykkä liikkuminen, hampaiden narskuttaminen ja hevonen saattaa makailla enemmän kuin normaalisti tai makuulta nouseminen on vaikea. Näiden havaitseminen saattaa olla hankalaa, koska monesti muutokset ovat alussa pieniä kun hevonen saaliseläimenä pyrkii piilottamaan kipunsa mahdollisimman pitkään. (Pesonen, 2018)

Kaupalliset ratkaisut kivun tunnistamiseen konenäöllä

Hevosen kivun tai sairauden tunnistamiseen konenäöllä ei löytynyt kaupallisia ratkaisuja. Magic Ai niminen yhdysvaltalainen startup-yritys teki StableGuard tuotetta mutta yrityksen tarina päättyi konkurssiin 2019. (GeekWire, 2019)

4 Hevosen hyvinvoinnin seuranta konenäöllä ja koneoppimisen avulla

4.1 Tavoite

Tavoitteena on seurata hevosen hyvinvointia konenäöllä ja tekoälyllä. Käytännössä se tarkoittaa hevosen olemuksen, ilmeiden, aktiivisuuden jne tunnistamista konenäöllä ja niiden muuttujien analysointia tekoälyllä. Käytännössä puhutaan koneoppimisesta, jossa koneoppimisen avulla muodostetaan malleja normaalista hevosen käyttäytymisestä, ilmeistä, aktiivisuudesta jne sen erottamiseksi mikä käytöksenä on epänormaalia.

4.2 Mitä

Hevosen kivun tarkkailemiseen on kehitty erilaisia menetelmiä, jotka perustuvat hevosen käyttäytymisen ja olemuksen tarkkailemiseen. Näistä on muodostettu kipuasteikkoja, jotka on pisteytetty eri osa-alueiden mukaan. Näitä asteikkoja ovat mm. Horse Grimace Pain Scale (HGS)-, Composite Pain Scale (CPS)- sekä Equine Acute Abdominal Pain Scale 1 (EAAPS-1)-kipuasteikko. Asteikkojen avulla on mahdollista miettiä osa-alueita, jotka soveltuisivat konenäön ja tekoälyn tunnistamiksi hevosen käyttäytymis- tai olemuspiirteiksi.

Horse Grimace Pain Scale perustuu hevosen kasvojenilmeisiin.

Kuva 2. Horse Grimace Pain Scale – kipuasteikko (Development of the Horse Grimace Scale (HGS))

<p style="text-align: center;">Stiffly backwards ears</p>  <p style="text-align: center;">Not present (0) Moderately present (1) Obviously present (2)</p> <p>The ears are held stiffly and turned backwards. As a result, the space between the ears may appear wider relative to baseline.</p>	<p style="text-align: center;">Orbital tightening</p>  <p style="text-align: center;">Not present (0) Moderately present (1) Obviously present (2)</p> <p>The eyelid is partially or completely closed. Any eyelid closure that reduces the eye size by more than half should be coded as "obviously present" or "2".</p>
<p style="text-align: center;">Tension above the eye area</p>  <p style="text-align: center;">Not present (0) Moderately present (1) Obviously present (2)</p> <p>The contraction of the muscles in the area above the eye causes the increased visibility of the underlying bone surfaces. If temporal crest bone is clearly visible should be coded as "obviously present" or "2".</p>	<p style="text-align: center;">Prominent strained chewing muscles</p>  <p style="text-align: center;">Not present (0) Moderately present (1) Obviously present (2)</p> <p>Straining chewing muscles are clearly visible as an increase tension above the mouth. If chewing muscles are clearly prominent and recognizable the score should be coded as "obviously present" or "2".</p>
<p style="text-align: center;">Mouth strained and pronounced chin</p>  <p style="text-align: center;">Not present (0) Moderately present (1) Obviously present (2)</p> <p>Strained mouth is clearly visible when upper lip is drawn back and lower lip causes a pronounced "chin".</p>	<p style="text-align: center;">Strained nostrils and flattening of the profile</p>  <p style="text-align: center;">Not present (0) Moderately present (1) Obviously present (2)</p> <p>Nostrils look strained and slightly dilated, the profile of the nose flattens and lips elongate.</p>

Taulukon kuvista on nähtävissä hevosen kasvojen eri osista havaittavat piirteet, jotka osoittavat kipua sekä pisteytys, miten ne ovat havaittavissa. Kasvojen ilmeitä voi olla karsinassa haastava havaita, jos kamera tarkkailee yläviistosta tai katosta karsinaa. Korvat ja silmät ovat todennäköisesti parhaiten havaittavissa.

Composite Pain Scale (CPS)

Composite Pain Scale muodostuu useista osa-alueista, joista osa on fysiologisia ruumiintoimintoja ja edellyttää mittaamista kuten syke ja ruumiinlämpö. CPS sisältää kuitenkin useita osa-alueita, jotka olisivat havaittavissa konenäöllä. Näitä ovat oman arvioni mukaan:

1. Olemus
 - Pirteä, matala pää ja korvat <-> levoton, liikkuu jatkuvasti
2. Hikoilu
 - Ei hikoile <-> hiestä märkä
3. Mahan potkiminen
 - Seisoo hiljaa
 - Satunnaista potkimista (1-2krt/5min)
 - Toistuvaa potkimista (3-4krt/5min)
 - Jatkuvaa potkimista (yli 5krt/5min), yrittää mata ja piehtaroida
4. Maan kuopiminen
 - Seisoo hiljaa <-> jatkuvaa kuopimista (yli 5krt/min)
5. Asento
 - Seisoo hiljaa, kävelee normaalisti
 - Satunnaista painon siirtelyä lievää lihasvapinaa
 - Ei kannata painoa jalalla, epänormaali painon jakautuminen
 - Yrittää virtsata, makaa, lihasvapinaa
6. Pään liikkeet
 - Ei merkkejä epämukavuudesta, pää suurimman osan ajasta suoraan eteenpäin
 - Ajoittaisia pään liikkeitä sivu- tai pystysuunnassa, satunnaista kylkien katselu (1-2krt/5min), huulen rullaus (1-2krt/5min)
 - Ajoittaisi ja nopeita pään liikkeitä sivu- tai pystysuunnassa, toistuvaa kylkien katselua (3-4 krt / 5 min), huulen rullaus (3-4 krt / 5 min)
 - Jatkuvia pään liikkeitä, jatkuvaa kylkien katselu (yli 5 krt / 5min), huulen rullaus (yli 5 krt / 5min)
7. Ruokahalu
 - Syö heinää mielellään <-> ei kiinnostu heinästä eikä syö

Kuva 3. Hikoileva hevonen (Holistic Horse)



Kuva 4. Ähkyilevä hevonen katselee kylkiään (University of Pennsylvania, School of Veterinary Medicine)



Kuva 5. Huulien rullaus (Saillet)



Kuva 6. Kuopiva hevonen (The Horse)



Kuva 7. Vatsaansa potkiva hevonen (Horse-Canada.com)



Kolmas asteikko on Equine Acute Abdominal Pain Scale 1 (EAAPS-1). Se on yksinkertaisuudessaan seuraava:

KÄYTTÄYTYMINEN	PISTEET
Apaattisuus	1
Kylkien katselu	1
Painon siirtely	2
Levottomuus	2
Mahan potkiminen	3
Maan kuopiminen	3
Venyttely	3
Rinnan päällä makaaminen	3
Makuulle menon yrittäminen	3
Kyljellään makaaminen	4
Piehtarointi	4
Maahan rojahtaminen	5

Kaikkien taulukoiden pisteytys mahdollistaa myös antaa kriteeristöä tekoälylle analysoida kuvamateriaalia ja mahdollista ongelmaa.

4.3 Mitä asioita konenäöllä tulisi pyrkiä etsimään?

Määrittelin tunnistettavat asiat sen perusteella, kuinka helposti arvelen niiden olevan tehtävissä.

1. Aktiivisuus

- a. Aktiivisuutta pitäisi pystyä seuraamaan sekä karsinassa että tarhassa tai laitumella. Aktiivisuuden seuraamiseen pitäisi riittää yksinkertaisimmillaan liikkeen tunnistus, jonka perusteella voidaan laskea montako kertaa minuutissa tai tunnissa liikettä havaitaan. Opettamiseen tarvitaan todennäköisesti aika laaja materiaali, jotta päästäisiin kohtuulliseen luotettavuuteen.
- b. Aktiivisuudessa pitäisi päästä myös havaitsemaan hevosen lepääminen.

Kuva 8. (Kippola, ilmakuva laitumesta)



Aktiivisuus laitumella. Ilmakuvasta näkee selkeästi, miten hevonen on liikkunut laitumella ja missä on alueet, jossa vietetään eniten aikaa (ruskeat läikyt).

2. Mahan potkiminen sekä maan kuopiminen

- a. Mahan potkiminen sekä maan kuopiminen ovat molemmat erottuvaa liikkeitä. Molemmat seurattavissa sekä karsinasta että laitumelta ja tarhasta.

3. Maan kuopiminen

4. Asento

- a. Normaalit liikkeet kuten seisominen ja kävely on erotettavissa painon siirtelystä jalan lepuuttamiseen ja virtsausyrityksiin, piehtarointiin ja makaamiseen sekä lihasvapinaan. Noista liikkeistä osa on tunnistettavissa tarhassa ja laitumella riippuen etäisyydestä kameraan ja kameran sijoittelusta.

Kuva 9. (Kippola, Piehtaroiiva hevonen)



5. Pään liikkeet

- a. Normaalit pään liikkeet erottuvat pään sivuttaisista tai pystysuunnassa tehtävistä liikkeistä sekä kylkien katselusta ja huulen rullauksesta. Näistäkin osa pystytään havaitsemaan suhteellisen kaukaakin eli pään liikkeet soveltuvat myös laitumella seurattavaksi.

6. Ruokahalu

- a. Ruokahalua on helppo tarkkailla karsinassa. Laitumella ja tarhassa tämä voi olla haastava. Erityisesti laitumella syömistä voi olla hankala päätellä muusta kuin hevosen asennosta eli syöminen on mahdollisesti pääteltävissä välillisesti.

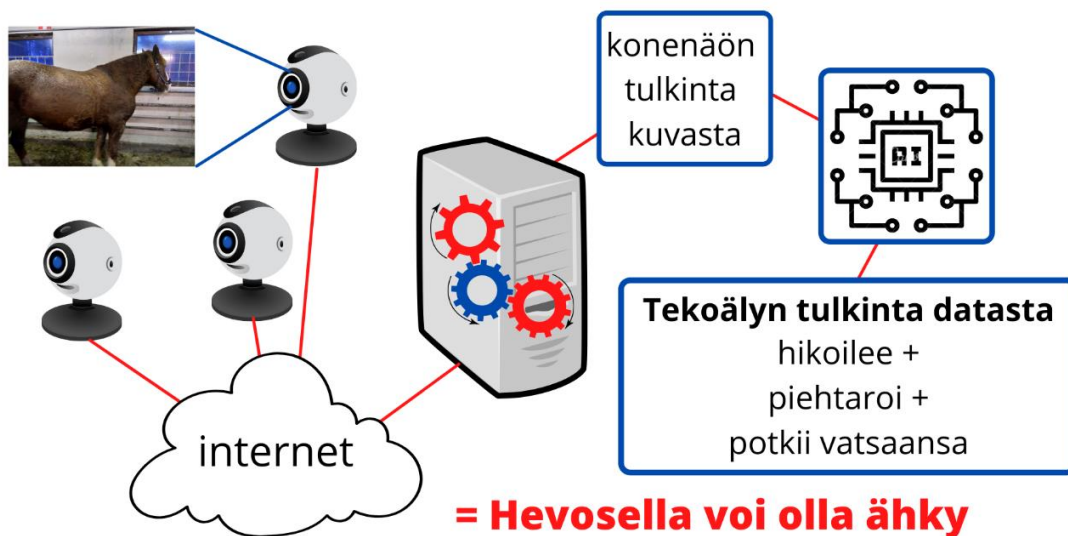
Kuva 10. (Kippola, Hevosia laitumella lisäruokittuna kuivaheinällä.)



5 Proof of concept ratkaisu hevosen hyvinvoinnin seurantaan

Hevosen hyvinvoinnin seuraamiseen perustuva järjestelmä perustuu kameroihin, konenäköön ja tekoölyyn.

Kuva 11. (Kippola, Konenäköjärjestelmä)



Konenäön tehtävä on tunnistaa hevosen liikkeitä, ilmeitä, olemusta kuten piehtarointia tai vatsan potkimista, korvien asentoa ja liikkumista sekä sen perusteella tuottaa tekoölylle havaintoja eli dataa. Tekoölyn tehtävä on tunnistaa datasta mikä on hevosen luontaista käytöstä ja mikä on poikkeama. Poikkeamista täytyy tehdä ilmoitus eteenpäin ihmiselle, joka voi varmistaa havainnon ja tuota voidaan käyttää edelleen oppimisen vahvistamiseen joko hyväksymällä havainto oikeaksi tai toteamalla se vääräksi.

5.1 Konenäköjärjestelmän kokeilu

Ensimmäisen testin lähdin tekemään Amazon Rekognitionilla. Se on osa Amazon Web Servicesin (AWS) palvelutarjontaa. Amazon Rekognition on pilvipohjainen (SaaS) konenäköalusta, joka

tarjoaa työkalut tekoälyn opettamiseen erilaisiin konenäön tehtäviin. Se tarjoaa kaksi API-rajapintaa (Application programming interface) eli toisen kuville ja toisen videolle. Testeissä käytin pelkästään kuvarajapintaa ja kokeilin miten helppo konenäkö on saada tunnistamaan hevonen ja kuvasta hevosen korvat. Rekognitionin käyttö perustuu tekoälyn opettamiseen ja luokitteluun (label). Prosessi etenee seuraavasti:

1. Kerää kuvia
2. Muodosta opetus datasetti
3. Muodosta testi datasetti
4. Opetta mallia
5. Arvioi mallin toiminta
6. Käytä mallia

Rekognition tarjoaa työkalut, jossa opetuskuviin merkitään mitä kuvasta halutaan etsiä.

Esimerkkinä datasetin muodostaminen Rekognitionilla lataamalla omia kuvia. Rekognitionissa on mahdollista käyttää valmiita tai Amazonissa jo olevia kuvia.

Kuva 12. Datasetin muodostaminen Rekognitionilla

Dataset details


Dataset name

The dataset name can't be more than 50 characters. It needs to be a valid S3 path with no spaces.


Image location

Import images from one of the options below.


Import Images labeled by Amazon SageMaker Ground Truth
Provide the location of your .manifest file. If you've labeled datasets in a different format, convert them to a .manifest format.




Import images from Amazon S3 bucket
Use images from an existing S3 bucket by entering the S3 folder location below. You have the option to automatically add labels based on your folder names.



Copy an existing Amazon Rekognition Custom Labels dataset
Use an existing dataset as a starting point for your new dataset. Your original dataset will remain unchanged.




Upload images from your computer
Add images by dragging and dropping them into your dataset gallery view. You're limited to uploading 30 images at one time.



Kuviin merkitään (label) asia, jota halutaan tunnistaa piirtämällä sen ympärille laatikko.

Kuva 13. AWS - kuvien merkitseminen



Jonka jälkeen muodostetaan opetus datasetti

Kuva 14. Opetussetin muodostaminen

Models (1)							
Name	Date created	Training dataset	Testing dataset	Model performance	Model status	Status message	
Hevosien_kipu.2021-10-24T15:23:45	October 24, 2021	Hevosien_kipu	Hevosien_kipu	N/A	TRAINING_IN_PROGRESS	The model is being trained.	

Omat kokeilut osoittautuivat haasteelliseksi eli yritin opettaa konenäön tunnistamaan hevosen korvat, koska ajattelin että se olisi tarkkuuden suhteen mielenkiintoinen asia tehdä. Haasteeksi tuli löytää riittävästi kuvia erilaisista hevosista eri valaistuksessa ja ympäristössä. En löytänyt suoraa vastausta paljonko kuvia tulisi olla mutta, jonkinlaisena nyrkkisääntönä tuntui olevan muutama tuhat mutta mitä enemmän sen parempi. Datasetsien testaaminen oli myös aika hidasta eli kun datasetti oli muodostettu ja sillä opetettiin uutta mallia AWS:ään käytettäessä kestää aika kauan ennen kuin AWS saa käytyä sen läpi ja ilmoitettua onko se mennyt läpi vai onko sen kanssa tullut joku virhe. Yleisin virhe itselläni oli liian vähäinen kuvamäärä.

Kuva 15. Konenäön tunnistamat hevoset



Ongelmat ja haasteet:

Riittämätön määrä kuvia opetusmateriaalina tuotti useamman kerran virheilmoituksen ja pyynnön lisätä kuvia opetusdatasettiin.

Kuva 16. Riittämätön määrä kuvia opetusmateriaalia

<input type="radio"/>	Hevosien_kipu	1	2021-10-24			
<input type="radio"/>	Hevosien_kipu.2021-10-24T15.23.45		2021-10-24	N/A	TRAINING_FAILED	The test dataset does not contain enough information to determine the quality of your model. Add more images to the test dataset. If you are using auto-split to create a test dataset, add more images to the training dataset.


Toinen kokeilu - Vision Appster

Vision Appster on suomalaisten kehittämä visuaalinen kehitysympäristö konenäköön. Vision Appsterin käyttö perustuu graafiseen käyttöliittymään. Käyttöliittymän avulla on helppoko konfiguroida erilaisia konenäköön liittyviä toimintoja. Ohjelma yhdistelee useita konenäkökirjastoja ja niihin liittyviä kuvankäsittelyn algoritmejä.

Vision Appsterilla voidaan luoda konenäkösovellus valitsemalla ohjelman työkaluista (Tools) halutut ja konfiguroimalla ne haluttuun toimenpiteeseen. Ohjelmalla voidaan julkaista (deploy) konenäkösovelluksia hyödyntäen Vision Appster Engineä tai Raspberry PI-ympäristöä, jolloin konenäkösovellusta voidaan ajaa suoraan Raspberry PI:stä rakennetussa paketissa, jossa on sekä tiedonkäsittely että kamera samassa.

Alla on kuva Vision Appsterin käyttöliittymästä, josta on nähtävissä käyttöliittymän toiminta. Sovellus muodostetaan kuvalähteestä kuten IP kamerasta, webbikamerasta tai hakemistossa olevista kuvista sekä halutusta määrästä työkaluja. Kuvassa sovellusta käytetään esineen tunnistamiseen. Koko prosessi esitetään visuaalisesti kuvalähteestä kuvankäsittelyn kautta koneoppimisen algoritmien kautta esikatseluun ja hahmon tunnistamiseen, jossa konenäkö tunnistaa sille esitettävän objektin (esimerkissä kuppi).


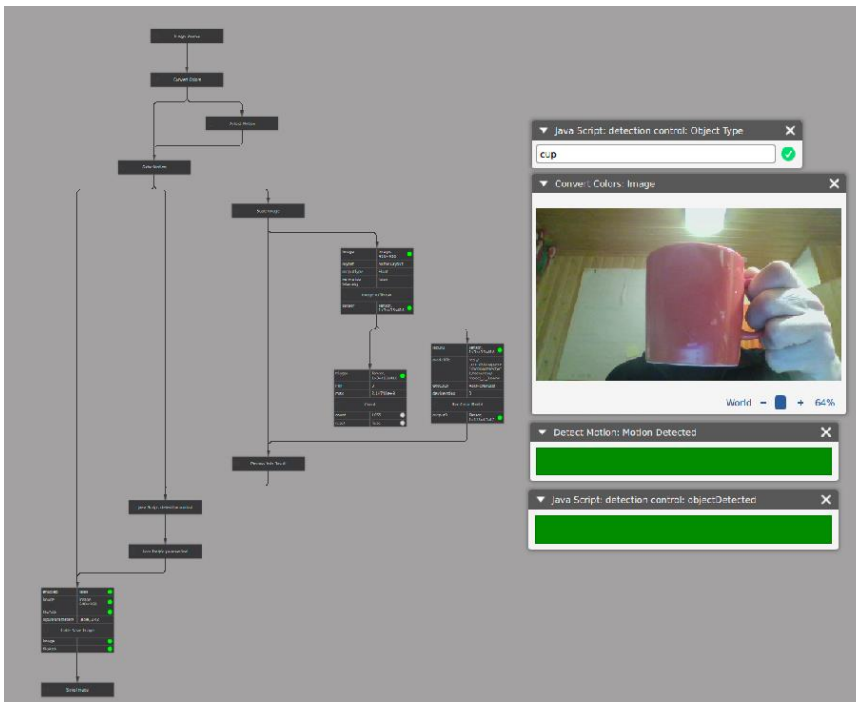
Kuva 17. Vision Appster käyttöliittymä; konenäkö tunnistaa kupin. Kuva Markku Kippola



Aktiivisuuden tunnistaminen konenäöllä

Testasin ajatustani aktiivisuuden mittaamisesta Vision Appsterilla yhdistämällä liikkeen- ja hahmon tunnistamisen laskuriin.

Kuva 18. Liikkeen laskeminen



Ideana oli siis tunnistaa liike ja tunnistettava objekti. Periaatteessa yhdistelmä toimi eli Vision Appster laski kupin heiluttelut kameran edessä.

5.2 Konenäköjärjestelmän kokeilun tulokset

Amazon Web Servicesin Rekognitionilla tehdyt kokeilut datasettien eli opetusaineiston muodostamisesta osoittivat, että opettamista varten tarvitaan paljon laajempi aineisto, jonka tulisi kattaa kuvia eri valaistusolosuhteissa eli kun tallissa ei ole valoja mutta päivänvalo riittää kameralle, tavallinen valaistus ja pimeän ajan kuvat, kun kamera käyttää infrapuna. Infrapuna vaikuttaa vielä kuvien laatuun ja todennäköisesti havainnot ovat huonompia eli kuvasta voidaan havainnoida lähinnä aktiivisuutta. Ohessa kuvat valaistuksen vaikutuksesta. Vasemmalla puolella karsinoiden yläpuolella olevat valaisimet parantavat oleellisesti karsinan valaistusta ja hevosten havainnointia karsinassa.

Kuva 19. Infrapunalla kuvattu talli. Kuva Markku Kippola



Kuva 20. Talli normaalivalaistuksessa. Kuva Markku Kippola



Vision Appster antoi hyvän ajatuksen mitä konenäöllä olisi mahdollista tehdä ja toi konkretiaa konenäön kokeilusta. Sillä on myös mahdollista tehdä ensimmäiset kokeilut ilman koodaamista. Pidemmälle menevä konenäön ja tekoälyn käyttö tulee väistämättä vaatimaan myös koodaamista.

5.3 Haasteet kokeilussa

Tarkoituksena oli ulottaa kokeilut talliin wlan-kameroilla. Tätä tarkoitusta varten asensin talomme yläkertaan wlan-tukiaseman, joka oli taloverkossa ja siten 200Mb valokuituyhteydessä kiinni. Yläkerran ikkunasta on suora näköyhteys talliin ja tallin ikkunoihin ja wlan-signaalia mitattaessa yhteys ulottuisi talliin. Tästä huolimatta wlan-kameroita ei saanut liitettyä wlan-tukiasemaan eli mahdollisesti ikkunoissa olevat metalliristikot estävät signaalia ikkunoista ja rakenteet muuten vaimentavat sen niin ettei yhteys wlan-kameroihin onnistunut.

Tallissa on jo pidempään ollut Arlo Go valvontakamera, joka on enemmän ns. riistakameratyyppinen ratkaisu. Kameran lähettämää kuvaa voi katsella kameran omalla sovelluksella. Kameran asemointi ei kuitenkaan mahdollista yhden yksittäisen hevosen hyvinvoinnin tarkkailua ja jättää runsaasti pimeitä kulmia, minne kamera ei näe. Kamera sopiikin paremmin ihmiselle hevosten yleistilan vilkaisuun.

Kuva 21. Arlo Go kamerakuvaa tallista



Haasteensa asetti myös AWS:n Rekognitioinin opettaminen. Laadukas tekoälyn opettaminen vaatii suuren määrän kuvia eli pitäisi olla laadukasta dataa käytettävissä. Yritin hakea valmiita datasettejä mutta hevosiin liittyen aineistoa on aika vähän. Valmiina löytyi AWS:lle tehty toteutus havainnoida hevosen ontumista.

5.4 Haasteet konenäön ja tekoälyn käytössä

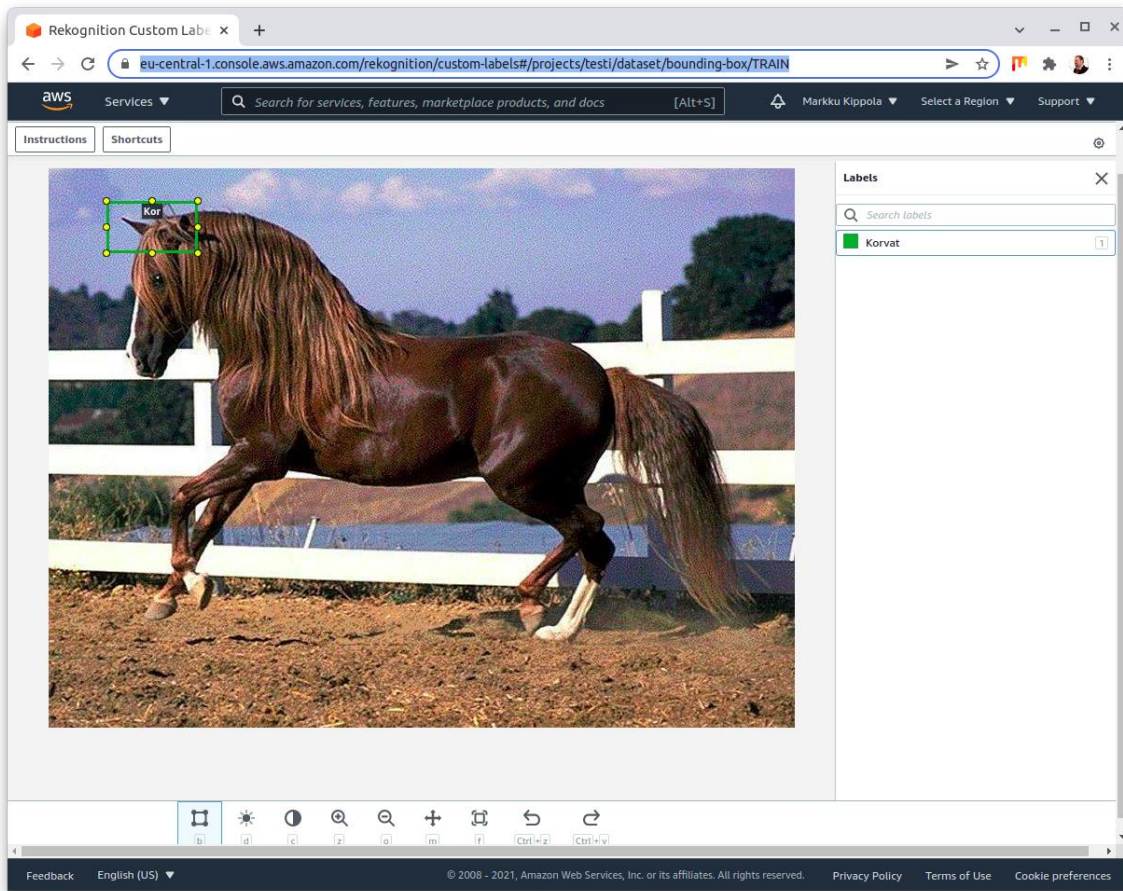
Haasteena oli myös AWS:n Rekognitionin opettaminen. Yritin löytää valmiita datasettejä. Joitakin hevosaiheisia löytyi, joita voisi käyttää siihen, että tunnistetaan hevonen mutta sellaista, josta olisi

ollut oikeasta apua tässä vaiheessa ei löytynyt. Olisi siis luotava itse laadukas datasetti, joka olisi tarpeeksi iso kooltaan sisältäen silloin tuhansia kuvia. Analogia tässä on yksinkertainen eli mitä enemmän dataa tekoälyllä on käytettävissä sitä paremmin haluttujen asioiden tunnistaminen toimii avustetussa koneoppimisessa.

Oma data koostui pienestä määrästä opetuskäyttöön soveltuvia kuvia, joissa kuvissa oli vain omia hevosia. Toimivan mallin kehittämiseksi pitäisi saada käyttöön tuhansia kuvia erilaisista hevosista, jotta voisi olla varma, että konenäkö toimii riittävällä tarkkuudella. Pienellä määrällä vaarana on, että konenäkö tunnistaa pelkästään esim. ruskeat hevoset eli malli vääristyy opetusmateriaalista.

Vaikka omassa datasetissä oli vähän kuvia, oli sen käsittely hidasta. Kaikki kuvat täytyy käsitellä manuaalisesti eli piirtää (bounding box) kuvaan mitä tunnistetaan ja merkitä se (Kuvan esimerkissä korvat).

Kuva 22. Korostettu tunnistettava asia ja annettu sille tunniste: ”korvat”



Mietin ähkyn tunnistamista, koska siihen liittyy monia tunnistettavia asioita ja käytännössä ähkyn tunnistamiseen täytyisi saada datasetti rakennettua ähkyileivistä hevosista. Osan kuvamateriaalin osalta löytyy generistä kuvamateriaalia eli vaikkapa hikoileva hevonen mutta mahan potkiminen jne on jo oireiden mukaista ja sellaisia kuvia ei löydy valmiina.

5.5 Suunnitelma jatkosta

5.5.1 Konenäkö ja tekoäly


Kokeilut Amazon Web Servicesin Rekognitionilla ja Vision Appsterilla osoittivat, että konenäöllä on mahdollista saada ainakin vähimmäinen tieto, jota ajattelinkin hevosten hyvinvoinnin

seurantaan eli aktiivisuus. Tämän toteutus on helpohko ja toteutettavissa esim. Vision Appsterilla, jolla onnistuu helposti toteuttaa konenäkösovellus, joka tunnistaa kohteen ja liikkeen.

5.5.2 Kamerajärjestelyt

Hyvinvoinnin seuraaminen edellyttää, että kameroista olisi saatavissa kuvaa kohdistuen aina yhteen hevoseen. Olen hankkimassa talliin nyt riittävän luotettavaa mobiilia internet-yhteyttä, joka mahdollistaisi striimaamisen eli videokuvan lähettämisen neljältä kameralta.

Kuva 23. (Kippola, Tallin pohjapiirustus kameroilla)



Kamerat sijoitetaan niin että ne kuvaavat yhtä karsinaa kukin. Näin ei tarvitse tehdä hevosen tunnistamista konenäöllä, vaikka se olisi mahdollista ja liittyy jatkosuunnitelmiin. Suunnitelmissa on siis toteuttaa myös laitumen tarkkailu konenäöllä. Siihen liittyy se, että konenäön on silloin kyettävä tunnistamaan hevoset ja antamaan hevoskohtaisesti ainakin, joku indeksiluku hevosen aktiivisuudesta.

5.5.3 Äänen hyödyntäminen

Arlo Go:ssa on myös mikrofoni ja se on johtanut myös miettimään äänen käyttöä. Hevosia on varsin mukava katsella illalla Arlost ja kuunnella tyytyväisten hevosten syömisääniä. Ääntä voisi mahdollisesti käyttää täydentämään kuvan tuottamaa informaatiota.

5.5.4 Tunnistaminen kauempaa

Yksi tulevaisuuden selvitettävistä asioista on, miten hevosen voi konenäöllä tunnistaa kauempaa. Tämä on tärkeää, kun hevoset ovat laitumella. Hevosen omistaja tunnistaa hevosensa kyllä helposti laumasta hyvin toistensa näköisiä hevosia. Jokaisella hevosella on kumminkin omat tapansa liikkua ja elehtiä. Ne ovat tunnistettavissa paljain silmin aika kaukaakin. Voiko tämän ulottaa konenäöllä ja tekoälylle ja havaitseeko se ne liikkeet ja manööverit samaan tapaan?

5.5.5 Tekoäly

Konenäön pystyessä tunnistamaan hevosesta parhaimmillaan kipuilmeitä ja kevyemmässä toteutuksessa pelkästään aktiivisuutta on mahdollista ohjata tätä dataa tekoälytoteutukselle hyvinvoinnin analysointia varten.

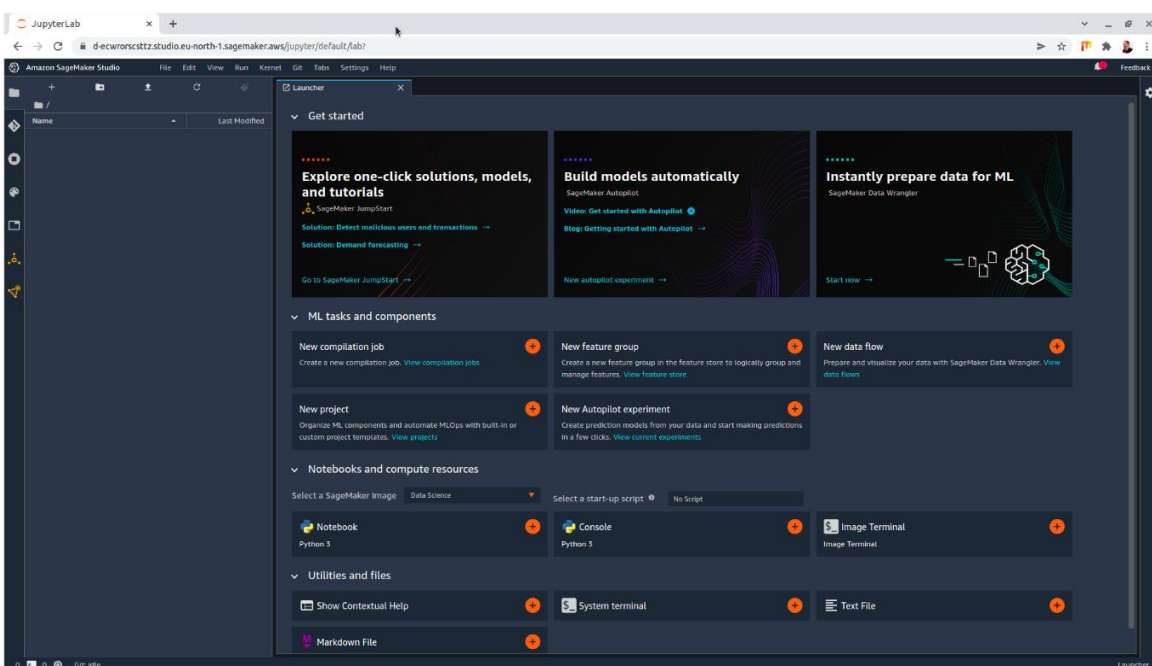
5.5.6 Amazon Sagemaker kehitysympäristö

Amazon Sagemaker on Amazonin tarjoama kehitysympäristö toteuttaa tekoälysovelluksia. Se on integroitu koneoppimisen ympäristö, jossa voi rakentaa, kouluttaa, julkaista ja analysoida luotuja tekoälymalleja samassa sovelluksessa. Se tarjoaa erilaisia työkaluja ja mahdollistaa saumattomasti kehittämisen. Mielenkiintoiseksi vaihtoehdoksi Vision Appsterin rinnalle sen nostaa Amazon SageMaker Studio, joka tarjoaa webbipohjaisen integroidun kehitysympäristön (IDE), jossa yhdessä visuaalisessa käyttöliittymässä voi:

- Kirjoittaa ja suorittaa koodia Jupyter notebookeissa

- Tehdä ja harjoittaa koneoppimisen malleja
- Julkaista malleja ja tarkkailla niiden ennusteiden tarkkuutta
- Seurata ja korjata koneoppimisen kokeiluja

Kuva 24. Amazon Sagemaker käyttöliittymä



Amazon Sagemaker tukee monia suosittuja syväoppimisen ohjelmistokehyksiä (framework) kuten TensorFlow, Apache MXNet, PyTorch jne mahdollistaen niille jo toteutettujen mallien soveltamisen samassa ympäristössä. (Amazon, 2021)

5.5.7 Valmiit datasetit

Valmiit datasetit helpottaisivat sekä konenäön että tekoälyn kehitystä. Näitä datasettejä löytyy yleisimpiin konenäön tehtäviin, kuten vaikka ihmisten kasvojen tunnistamiseen. Valmiit datasetit mahdollistaisivat oppimisen siirtämisen -tekniikoiden käytön (transfer learning), jotka nopeuttavat


tekoälyn opettamista. Niissä idea käyttää painokertoimia, jotka on lasketut toisella datasetillä. Näin uudella sovelluksella voidaan saavuttaa riittävä suorituskky nopeasti. (Kananen & Puolitaival, 2019, p. 209)

BigTransfer (BiT) on joukko valmiiksi koulutettuja malleja, jotka voidaan siirtää erinomaisen suorituskvyn saavuttamiseksi uusissa dataseiteissä, jopa vain muutamalla kuvalla per datasetti. Nämä mallit on koulutettu suuria datasettejä (jopa 300 miljoonaa kuvaa) ja tiettyjä neuroverkkoarkkitehtuureja vasten. BiT tarjoaa suurella datamäärällä valmiiksi koulutettuja malleja, joissa painotuksia tarvitsee säätää kohteen mukaan säästäten näin suuresti aikaa. (Kolesnikov, et al.)

Objektien tunnistamiseen löytyy erilaisia datasettejä. Tensorflowssa on esimerkiksi objektien tunnistamiseen tarjolla valmiita datasettejä kolmisensataa kappaletta niin äänen, kuvien kuin tekstin käsittelyyn. (TensorFlow, n.d.)

Datasettejä löytyy myös kaupallisilta toimijoilta maksua vastaan. Näitä löytyy esimerkiksi Amazonin AWS Marketplacelta. Erilaisia koneoppimisen ratkaisuja (ML Solutions) löytyy tätä kirjoitettaessa 830 kappaletta. Niiden joukossa mm. ElectrifiAI:n "Equine Gait Model" eli malli hevosen kävelemisestä, jota voisi käyttää apuna tunnistamaan videolta hevosen ontumista.

Kuva 25. Ontuvan hevosen tunnistamisen malli (Equine Gait Model) (ElectrifAI)



5.5.8 Tensorflow

Tensorflow on alun perin Googlen kehittämä. TensorFlow on avoimeen lähdekoodiin pohjautuva koneoppimisen alusta. Se tarjoaa kattavat työkalut, kirjastoja ja yhteisön resursseja helpottamaan tekoälysovellusten tekemiseen ja julkaisemiseen. Se on Apache 2.0:n mukaan lisensoitu eli BSD-tyyppisesti lisensoitu, joka mahdollistaa koodin uudelleenkäytön kaupallisesti.

Tensorflow pohjautuu Python ohjelmistokieleen ja se suorittaa numeerista laskentaa käyttäen tietovirtakaavioita. Nämä kuvaavat, kuinka dataa siirretään kaavioiden tai solmujen sarjan kautta. Kukin kaavion solmu edustaa matemaattista operaatiota. Solmujen väliset yhteydet muodostuvat moniulotteisesta tietotaulukosta eli tensorista. (DataScientist, n.d.)

5.5.9 OpenCV

OpenCV on alun perin Intelin kehittämä avoimen lähdekoodin konenäön ja koneoppimisen ohjelmistokirjasto. Intel kehitti sen nopeuttamaan konenäkösovelluksien yleistymistä. OpenCV on lisenssiehtojensa takia yrityksille hyvä ja helppo vaihtoehto. Tuote on BSD-lisensoitu eli se ei vaadi lähdekoodin julkaisemista ja sallii lisenssin muokkaamisen ja uudelleenkäytön kaupallisesti.

OpenCV:n kirjasto on erittäin laaja sisältäen yli 2500 optimoitua algoritmia eri tarkoituksiin kuten kasvojen havaitsemiseen ja tunnistamiseen, esineiden tunnistamiseen sekä liikkeen seuraamiseen. Kirjaston laajuudesta hyötyy yli 47 000 käyttäjää ja OpenCV:n arvioitu latausmäärä on yli 18 miljoonaa. (OpenCV, 2021)

5.5.10 PyTorch

PyTorch on avoimen lähdekoodin koneoppimisen kirjasto perustuen Torch-kirjastoon. Sitä käytetään sovelluksissa, kuten konenäkö ja luonnollisten kielten käsittely. PyTorchin taustalla on Facebookin AI Research Lab (FAIR). PyTorch on TensorFlown ja OpenCV:n tapaan julkaistu BDS-tyyppisellä lisenssillä, joka mahdollistaa kaupallisten sovellusten kehittämisen ja julkaisemisen. (Wikipedia, n.d.)

5.6 Objektien tunnistaminen


Objektien tunnistamiseen on olemassa erilaisia kirjastoja ja algoritmeja. Tässä esiteltynä kaksi tunnettua, joista molemmat voisivat sopia.

5.6.1 Haar kaskadi

Haar kaskadi on Paul Violan ja Michael Jonesin julkaisussa:” Rapid Object Detection using a Boosted Cascade of Simple Features” esittelemä koneoppimismenetelmä objektien tunnistamiseen kuvasta, joka pystyy käsittelemään kuvia nopeasti ja tunnistamisen tarkkuus on korkea. Julkaisussa esiteltiin kolme menetelmää, jotka loivat pohjan tehokkaalle menetelmälle eli integraalikuva, Adaboost algoritmiin pohjautuva piirteiden valinta ja kaskadina toimiva luokittelu.

Integraalikuva mahdollistaa nopean ominaisuuksien arvioinnin. Integraalikuviissa käytetään harmaasävykuvia. Integraalikuivassa pisteen (x, y) arvo on kaikkien vasemmalla ja yläpuolella olevien pikseleiden intensiteettien summa sisältäen myös pisteen (x, y) itsensä. Tällä tavoin voidaan laskea nopeasti suorakaiteen muotoinen alue. Haar-ominaisuuksien poimiminen kuvasta perustuu tummien ja vaaleiden suorakaiteen muotoisten alueiden laskemiseen. Integraalikuviä käyttämällä tämä laskenta on nopeaa.

Kuva 26. Ominaisuudet



Adaboost (Adaptive Boosting) -algoritmi on koneoppimisalgoritmi, joka valitsee parhaat ominaisuudet ja kouluttaa luokittelijat käyttämään niitä. Se käyttää yhdistelmää "heikkoja luokittelijoita" luodakseen "vahvan luokittelijan", jota algoritmi käyttää tunnistukseen objekteja. Lyhyesti Adaboost siis toimii yhdistämällä "heikkoja oppijoita" ja antamalla niille erilaisia painoarvoja sen perusteella kuinka hyvin tunnistus toimii. Erittäin huonosti toimiva luokittelija käännetään tavallaan peilikuvaksi eli väärin tulosten avulla opitaan ja algoritmi huomioi siten edellisten luokittelijoiden virheet uusissa luokitteluissa eli luokittelu paranee koko ajan.

Kaskadi luokittelija on monivaiheinen luokittelija, joka suorittaa tunnistamisen nopeasti ja tarkasti. Tunnistusprosessi muodostaa päätöspuusta, jota Viola & Jones kutsuvat kaskadiksi. Joka vaihe koostuu edellä esitellyn Adaboost-algoritmin tuottamasta vahvasta luokittelijasta ja joka vaiheessa heikkojen luokittelijoiden määrä vahvassa luokittelijassa kasvaa. Luokittelija syöte arvioidaan peräkkäin vaihe vaiheelta. Negatiivinen tulos luokittelijalta johtaa sen hylkäämiseen ja positiivinen tulos johtaa syötteen siirtymisen seuraavaan vaiheeseen. Kaskadin tarkoituksena on siis hylätä nopeasti suurin osa alueista ja tutkia tarkemmin mahdollisesti haluttuja piirteitä sisältäviä alueita. Kun kaikki kaskadin kerrokset on käyty läpi ilman hylkäämistä tarkoittaa se tunnistusta.

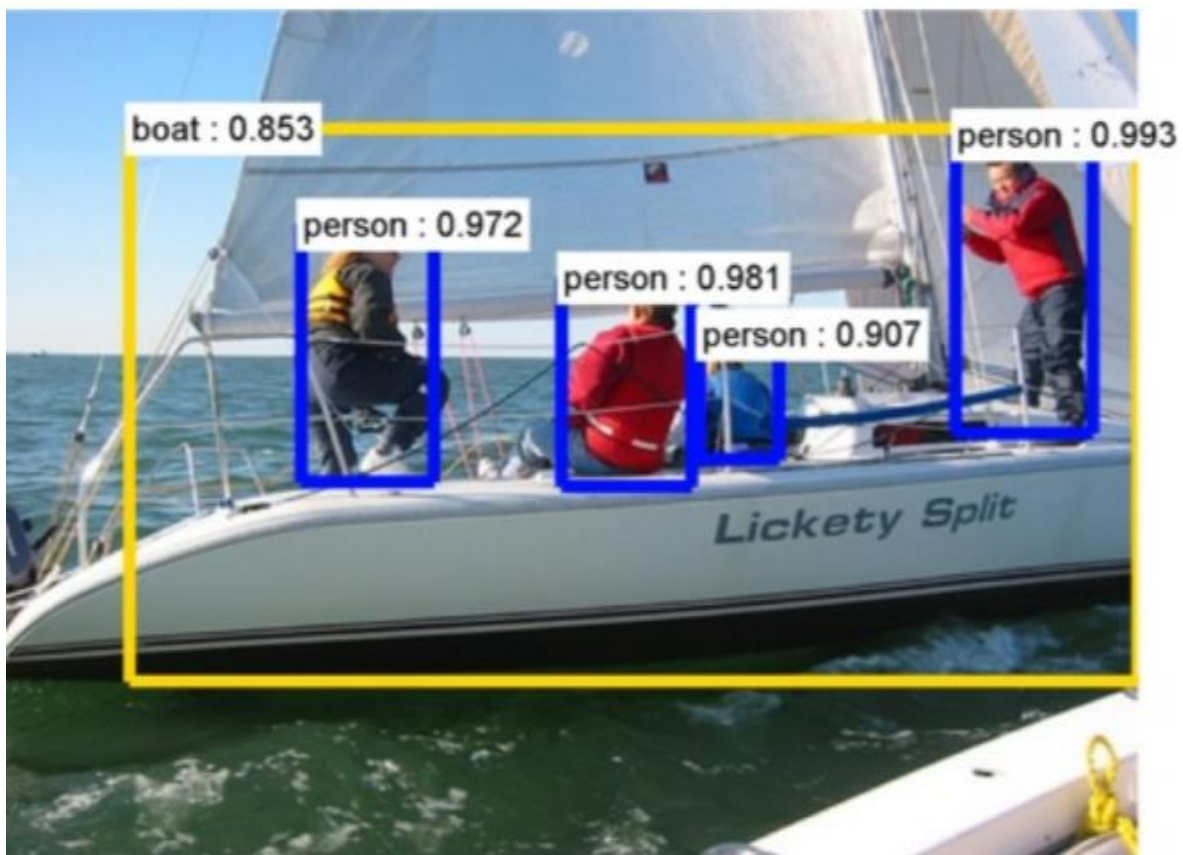
Kaskadin tarkoituksena on hylätä nopeasti suurin osa alueista ja tutkia tarkemmin mahdollisesti etsittäviä objekteja sisältäviä alueita. Tämä tapahtuu siten, että kytketään sarjaan useita luokittelijoita yksinkertaisista monimutkaisiin. Alun kevyet ja yksinkertaiset luokittelijat säädetään herkälle niin, että ne eivät hylkää kohdetta melkein koskaan, mutta kuitenkin hylkäävät suuren osan ei-kohteista. Tunnistus on kyseessä, kun kaikki kaskadin kerrokset on käyty läpi ilman hylkäämistä.

Haar kaskadin käyttö menetelmänä edellyttää siis paljon positiivisia kuvia halutusta objektista sekä negatiivisia kuvia missä objektia ei ole. Mallin opettaminen on hidasta mutta lopputuloksen pitäisi olla hyvä. (Viola & Jones, 2001)


5.6.2 Yolo (You only look once)

Yolo on neuvoverkkoja käyttävä algoritmi reaaliaikaiseen objektien tunnistamiseen. Yolo on suosittu sen nopeuden ja tarkkuuden takia ja sen avulla on tunnistettu liikennemerkkejä, ihmisiä ja eläimiä. Yolo käsittelee objektin tunnistamista regressio-ongelmana. Tällä tarkoitetaan tuloksen olevan numeerinen eli tulos ennustaa yhtäaikaaisesti objektin rajausruudut sekä luokittelutodennäköisyydet. Yolo:ssa siis ennustetaan yhdellä kertaa mitkä kohteet näkyvät kuvassa ja missä ne siinä sijaitsevat. (Khandelwal, 2019)

Kuva 27. Kohteiden tunnistus ja sijainti kuvassa (Science)

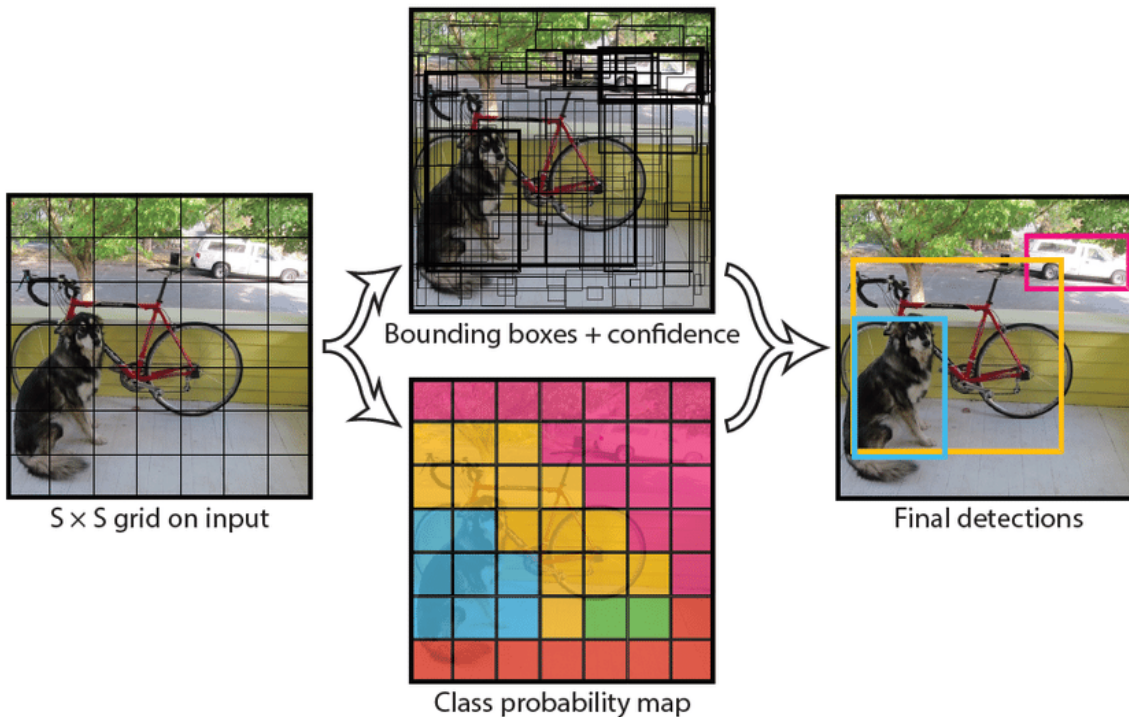


Kuva 28. Yolo: n periaate (You Only Look Once: Unified, Real-Time Object Detection)



Yolo on yksinkertainen. Yksi konvoluutioverkko (convolutional neural network – CNN) ennustaa samanaikaisesti useita rajausruutuja ja todennäköisyydet näille rajausruuduille. Yolo opetetaan täysillä kuvilla ja se optimoi suoraan tunnistamisen suorituskykyä. Yolo on nopea. Sen tapa käsitellä kuvaa ja jakaa se ruudukoksi, jossa ruudukot jaetaan luokkatodennäköisyyksien mukaan omiin luokkiinsa ja ruuduista muodostetaan rajausruutu objekteille perustuen niiden luotettavuuteen oikeana havaintona. Tämä havainto objektista luokitellaan ja ennustetaan kuvan objektien sijainti rajausruuduilla. Nämä yhdistetään ja saadaan lopullinen kohteentunnistus (kts kuva). (Redmon, Divvala, Girshick, & Farhadi, 2015) (Section.io, 2021)

Kuva 29. Yolo:n toimintaperiaate



6 Johtopäätökset ja pohdinta

Tietoisuus hevosen hyvinvoinnista ja hevosen kivun määrittämisestä on noussut viimeisen kymmenen kahdenkymmen vuoden aikana. Hevosen kipua on määritetty erilaisissa tutkimuksissa hoitotoimenpiteiden yhteydessä ja konkretisoitu hevosenomistajien ja eläinlääkärin hiljaista tietoa – ihmisten, jotka ovat opetelleet “lukemaan” hevosten ilmeitä, liikkeitä ja olemusta. Tätä kautta on kehittynyt erilaisia kiputaulukoita ja apuvälineitä, joiden avulla on helpompi tulkita hevosten kiputiloja. Nämä mahdollistavat myös teknologian ottamisen avuksi hevosen hyvinvoinnin seuraamiseen. Teknologinen kehitys on myös tuonut omat mahdollisuutensa. Erilaiset reaaliaikaiset konenäkö ja tekoälysovellukset ovat yleistyneet ja näyttävät esimerkkiä mahdollisuuksista.

Tämän tutkimuksen tavoitteena oli selvittää, miten hevosen hyvinvointia voidaan seurata konenäön ja tekoälyn avulla. Tähän liittyi oleellisesti olemassa olevien kaupallisten sovellusten

löytäminen. Tuotantoeläinten puolelta löytyi kaupallisia esimerkkejä ja paljon tutkimusta. Osa tuotantoeläinten sovelluksista sisälsi samantyyppisiä ominaisuuksia. Erona tuotantoeläimissä oli se että eläimiä käsiteltiin yleensä ryhmänä tai laumana ja sovellukset eivät samalla tavalla keskittyneet yksilöihin kuin oma ajatus on. Hevosiin liittyen kaupallisia ratkaisuja ei oikein löytynyt. Tätä kirjoittaessa nuo ratkaisut olivat jo konkurssiin menneet amerikkalainen yritys ja ruotsalainen Videquus AB, jonka löysin jo kirjoittaessani tätä johtopäätöksiä ja pohdintaa.

Omien kokeilujen osalta kohtasin pieniä vastoinkäymisiä kun livekuvan välittäminen tallista ei onnistunut hyödyntämällä wiania ja kiinteistössä olevaa valokuituyhteyttä vaan se tulee vaatimaan muita ratkaisuja kuten jonkinlaisen morkkulahteyden toteuttaminen. Pieni kokeilu wlan-kameroilla todisti että tallissa oleva wlan-verkko riittäisi sekä tallissa oleville kameroille että tallin läheisyydessä oleville kameroille ja mahdollistaisi myös ulkotarhojen tarkkailun. Ulkokameroiden osalta tulee selvittää miten tekoäly tulkitsee useasta datalähteestä tulevaa kuvaa samasta eläimestä.

Omat kokeilut eri konenäkö- ja tekoälyalustoilla osoittivat myös sen että tekoälysovellus, joka perustuu aktiivisuuteen on tehtävissä suhteellisen helposti mutta mentäessä pidemmälle kuten kipuilmisiin haasteet kasvavat ja se tulee vaatimaan myös olosuhteilta, kuten valaistukselta ja kameroiden sijoittelulta paljon enemmän, jotta data olisi hyvälaatuista ja tarkkaa.

Alustavat kokeilut onnistuivat niin hyvin että tulen jatkokehittämään ensimmäisiä laadittuja malleja. Tavoitteena on saada riittävästi hyvälaatuista opetusaineistoa hevosen peruseurantaan ja ensimmäinen konkreettinen toteutus olisi sovellus joka seuraisi hevosen käyttäytymistä tai aktiivisuutta karsinassa. Sovelluksen tehtävänä olisi siis lähinnä tunnistaa liikettä ja muutamia seurattavia kohteita kuten vesi- ja ruokakuppi sekä suolakivi. Uskon että näillä on mahdollista jo tunnistaa peruskäyttäytymistä ja tekoälyn mahdollista laatia sääntöjä hevosen käyttäytymiselle. Esimerkkinä vaikka että hevonen käy juomassa x kertaa y tunnin aikana ja tästä muodostaa poikkeama jos hevonen ei juo kertaakaan tietyssä ajassa.

Haasteita tulee olemaan varsinaisen sairausdatan saannissa. Hevosenomistajana en toivo hevosen sairastuvan ähkyyyn mutta sellaisesta tilanteesta saatava data olisi sovelluskehityksen kannalta kullanarvoista.

Tämän tutkimuksen tulokset ovat laajemmin käytettävissä eläinten hyvinvoinnin kehittämisessä niin tuotanto- kuin harrastus- ja lemmikkieläimilläkin. Peruseriaatteet sopivat niin naudan kuin kissankin hyvinvoinnin seurantaan. Tuotantoeläimillä toivoisin tämän tyyppisen teknologian leviävän laajalle käyttöön. Se tarjoaisi kuluttajille mahdollisuuden saada tietoa eläinten hyvinvoinnista ja tarjoavan suomalaisille tiloille kilpailuetua tarjoamalla eettisemmän vaihtoehdon. Esitellyt teknologiat, tekniikat ja sovellukset soveltuvat varsin laajasti käytettäväksi eri konenäön ja tekoälyn sovellusalueilla.

Lähteet

- A Hitch in the Giddyup*. (ei pvm). Haettu 27. 11 2021 osoitteesta Horse-Canada.com: <https://horse-canada.com/magazine/health/the-well-stocked-equine-medicine-cabinet/>
- Amazon. (2021). *Amazon SageMaker Documentation*. Haettu 16. 11 2021 osoitteesta <https://docs.aws.amazon.com/sagemaker>
- Behera, G. S. (24. 2 2020). *Face Detection with Haar Cascade*. Haettu 12. 11 2021 osoitteesta <https://towardsdatascience.com/face-detection-with-haar-cascade-727f68dafd08>
- Common Emergencies - Colic*. (ei pvm). Haettu 10. 9 2021 osoitteesta University of Pennsylvania, School of Veterinary Medicine: <https://www.vet.upenn.edu/veterinary-hospitals/NBC-hospital/services/emergency-critical-care/common-emergencies/common-emergencies---colic>
- DataScientist. (ei pvm). *Tensor flow : All about Google's Machine Learning framework*. Haettu 28. 10 2021 osoitteesta <https://datascientest.com/en/tensor-flow-all-about-googles-machine-learning-framework>
- Davies, E. R. (2012). *Computer and machine vision : Theory, algorithms, practicalities*. Elsevier Science & Technology.
- ElectrifAI. (ei pvm). https://github.com/ElectrifAi/model-aws-equine-gait-model/blob/main/lame_horse.mp4. Haettu 18. 11 2021
- Eläinsuojelulaki*. (2021). Haettu 14. 7 2021 osoitteesta Finlex- ajantasainen lainsäädäntö: <https://www.finlex.fi/fi/laki/ajantasa/1996/19960247>
- Empirica Oy. (2021). *Arla Iris - lehmien hyvinvointia seuraava tekoälysovellus*. Haettu 14. 10 2021 osoitteesta www.empirica.fi/arla-yhden-tilan-maito
- Farm Animal Welfare Committee (FAWC)*. (13. 7 2021). Noudettu osoitteesta *Assessment of farm animal welfare - Five Freedoms and a Life Worth Living*: <https://www.gov.uk/government/publications/fawc-report-on-farm-animal-welfare-in-great-britain-past-present-and-future>
- Fernandes, A.;Dórea, J.;& Rosa, G. (21. Lokakuu 2020). *Image Analysis and Computer Vision Applications in Animal Sciences: An Overview*. 21 October .

- Fernández-Carrión, E.;Martínez-Avilés, M.;Ivorra, B.;Martínez-López, B.;Ramos, Á.;& al., e. (2017). Motion-based video monitoring for early detection of livestock diseases: The case of African swine fever. *PLOS ONE*.
- GeekWire. (31. 2 2019). *Magic AI shuts down after failing to corral sufficient market for AI-powered horse monitoring tech*. Haettu 22. 11 2021 osoitteesta <https://www.geekwire.com/2019/magic-ai-shuts-failing-coral-sufficient-market-ai-powered-horse-monitoring-tech/>
- Gómez, Y.;Stygar, A. H.;Boumans, I. J.;Bokkers, E. A.;Pedersen, L. J.;Niemi, J. K.;. . . Llonch, P. (2021). A Systematic Review on Validated Precision Livestock Farming Technologies for Pig Production and Its Potential to Assess Animal Welfare . *Frontiers in Veterinary Science*, 492.
- Hevosien huulien rullaus*. (ei pvm). Noudettu osoitteesta Pixabay: <https://pixabay.com/images/id-1218138/>
- IBM. (ei pvm). *Machine Learning*. Haettu 26. 6 2021 osoitteesta <https://www.ibm.com/cloud/learn/machine-learning>
- Juustoportti Oy*. (ei pvm). Noudettu osoitteesta www.juustoportti.fi
- Kananen, H.;& Puolitaival, H. (2019). *Tekoäly : bisneksen uudet työkalut*. Alma Talent.
- Khandelwal, R. (27. 7 2019). *Computer Vision — A journey from CNN to Mask R-CNN and YOLO - Part 2*. Noudettu osoitteesta Towards Data Science: <https://towardsdatascience.com/computer-vision-a-journey-from-cnn-to-mask-r-cnn-and-yolo-part-2-b0b9e67762b1>
- Kielitoimiston sanakirja - konenäkö*. (ei pvm). Haettu 16. 7 2021 osoitteesta Kielitoimiston sanakirja: <https://www.kielitoimistonsanakirja.fi/#/konen%C3%A4k%C3%B6>
- Kippola, M. (ei pvm). *Hevosia laitumella lisäruokittuna kuivaheinällä*.
- Kippola, M. (ei pvm). *Konenäköjärjestelmä*.
- Kippola, M. (ei pvm). ilmakuva laitumesta. *Ilmakuva laitumesta*. Muhos.
- Kippola, M. (ei pvm). Piehtaroiiva hevonen. *Piehtaroiiva hevonen*. Muhos.
- Kippola, M. (ei pvm). *Tallin pohjapiirustus kameroilla*.
- KMVET. (6. 9 2018). *Euroopan ensimmäiset WQ-sertifioidut meijerit Suomessa*. Haettu 11. 11 2021 osoitteesta <https://kmet.fi/euroopan-ensimmaiset-wq-sertifioidut-meijerit-suomessa/>

- Kolesnikov, A.;Lucas, B.;Zhai, X.;Puigcerver, J.;Yung, J.;Gelly, S.;& Hounsby, N. (ei pvm). *Big Transfer (BiT): General Visual Representation Learning*. Google Research, Brain Team.
- Lukka, K. (2001). *Kari Lukka: Konstruktiivinen tutkimusote*. Haettu 19. 11 2021 osoitteesta <https://metodix.fi/2014/05/19/lukka-konstruktiivinen-tutkimusote/>
- Mark F. Hansen, M. L. (2018). Towards on-farm pig face recognition using convolutional neural networks. *Computers in Industry*, 145-152.
- Mathieu, M.;Jiangqiang, M.;Xiaocai, S.;Liyong, Y.;Peng, F.;Xuejun, Y.;. . . Yifan, Z. (2020). An adaptive pig face recognition approach using Convolutional Neural Networks. *Computers and Electronics in Agriculture*, Volume 173.
- Neethirajan, S.;& Kemp, B. (2021). Digital Livestock Farming. *Sensing and Bio-Sensing Research*, Volume 32.
- OpenCV. (30. 11 2021). *About*. Noudettu osoitteesta <https://opencv.org/about/>
- Oracle. (ei pvm). *What Is a Chatbot?* Haettu 12. 8 2021 osoitteesta <https://www.oracle.com/chatbots/what-is-a-chatbot/>
- Pesonen, P. (2018). Mitä on hevosen kipu ja miten se tunnistetaan? *Hevosenomistaja*, 22-23.
- Puusa, A.;Juuti, P.;& Aaltio, I. ((2020)). *Laadullisen tutkimuksen näkökulmat ja menetelmät*. Gaudeamus.
- Redmon, J.;Divvala, S.;Girshick, R.;& Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection.
- Ruokavirasto. (12. 8 2021). *Afrikkalainen sikarutto (ASF)*. Noudettu osoitteesta <https://www.ruokavirasto.fi/viljelijat/elaintenpito/elainten-terveys-ja-elaintaudit/elaintaudit/siat/afrikkalainen-sikarutto/>
- Saaranen-Kauppinen, A.;& Puusniekka, A. (25. 11 2020). *Menetelmäopetuksen tietovaranto*. Haettu 25. 11 2021 osoitteesta KvaliMOTV - Menetelmäopetuksen tietovaranto [verkkojulkaisu]. Tampere: Yhteiskuntatieteellinen tietoarkisto [ylläpitäjä ja tuottaja]. <<https://www.fsd.tuni.fi/menetelmaopetus/>>.
- Science, T. D. (ei pvm). <https://towardsdatascience.com/computer-vision-a-journey-from-cnn-to-mask-r-cnn-and-yolo-part-2-b0b9e67762b1>. Haettu 23. 11 2021

- Section.io. (15. 5 2021). *Introduction to YOLO Algorithm for Object Detection*. Haettu 19. 10 2021 osoitteesta <https://www.section.io/engineering-education/introduction-to-yolo-algorithm-for-object-detection/>
- Siukonen, T.;& Neittaanmäki, P. (2019). *Mitä tulisi tietää tekoälystä*. . Docendo.
- Smith, M. L.;Smith, L. N.;& Hansen, M. F. (15. 3 2021). The quiet revolution in machine vision - a state-of-the-art survey paper, including historical review, perspectives, and future directions. Centre for Machine Vision, Bristol Robotics Laboratory, University of the West of England, Bristol, UK.
- Strengths and Limitations of Equine Stress Measurements*. (ei pvm). Haettu 29. 10 2021 osoitteesta The Horse: <https://thehorse.com/149871/strengths-and-limitations-of-equine-stress-measurements/>
- TensorFlow. (ei pvm). *Models & datasets*. Haettu 11. 30 2021 osoitteesta <https://www.tensorflow.org/resources/models-datasets>
- The Verge. (ei pvm). *Twitter taught Microsoft's AI chatbot to be a racist asshole in less than a day*. Haettu 26. 6 2021 osoitteesta <https://www.theverge.com/2016/3/24/11297050/tay-microsoft-chatbot-racist>
- Tips for Managing Winter Colic*. (ei pvm). Haettu 24. 8 2021 osoitteesta Holistic Horse: <https://holistichorse.com/health-care/equine-nutrition-tips-for-managing-winter-colic/>
- Viola, P.;& Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Kauai, HI, USA.
- Wikipedia. (ei pvm). *A.I. Artificial Intelligence*. Haettu 8. 7 2021 osoitteesta https://en.wikipedia.org/wiki/A.I._Artificial_Intelligence
- Wikipedia. (ei pvm). *Koneoppiminen*. Haettu 2. 8 2021 osoitteesta <https://fi.wikipedia.org/wiki/Koneoppiminen>
- Wikipedia. (ei pvm). *PyTorch*. Haettu 30. 11 2021 osoitteesta <https://en.wikipedia.org/wiki/PyTorch>
- Wikipedia. (ei pvm). *Tekoäly*. Haettu 27. 6 2021 osoitteesta <https://fi.wikipedia.org/wiki/Teko%C3%A4ly>

(ei pvm). *You Only Look Once: Unified, Real-Time Object Detection*. Haettu 28. 10 2021 osoitteesta

<https://arxiv.org/pdf/1506.02640.pdf>

Zuech, N. (2000). *Understanding and Applying Machine Vision*. New York: Marcel Dekker, Inc.