



Vaasan yliopisto
UNIVERSITY OF VAASA

Iida Kuusimäki

Syväoppimisen soveltaminen pieneläinten diagnostiikassa

Tekniikan ja innovaatiojohtamisen
akateeminen yksikkö
Kandidaatintutkielma
Automaatio ja tietotekniikka

Vaasa 2025

VAASAN YLIOPISTO**Tekniikan ja innovaatiojohtamisen akateeminen yksikkö**

Tekijä:	Iida Kuusimäki		
Tutkielman nimi:	Syväoppimisen soveltaminen pieneläinten diagnostiikassa		
Tutkinto:	Tekniikan kandidaatti		
Oppiaine:	Automaatio ja tietotekniikka		
Työn ohjaaja:	Timo Mantere		
Valmistumisvuosi:	2025	Sivumäärä:	45

TIIVISTELMÄ:

Eläinlääketieteen diagnostiikassa syväoppimismalleja käytetään muun muassa sairauksien havaitsemiseen, luokitteluun ja aikaisen vaiheen hoitoennusteiden määrittämiseen. Hyödyntämällä konvoluutioneuroverkkoja, toistuvia neuroverkkoja ja siirto-oppimista, syväoppimista voidaan soveltaa monipuolisesti eläinlääketieteen tehtäviin. Myös perinteisiä koneoppimisalgoritmeja, kuten ohjattua, ohjaamatonta ja puoliohjattua oppimista, käytetään eläinlääketieteessä suurien datamäärien käsittelyssä. Koneoppimisen haaraa, luonnollisen kielen käsittelyä (NLP), voidaan hyödyntää digitaalisten dokumenttien luomisessa eläinlääkärien vapaamuotoisten muistiinpanojen pohjalta. Tutkielman tavoitteena on tarkastella, miten syväoppimismalleja on hyödynnetty pieneläinten sairauksien diagnostiikassa, erityisesti kuvantamisen yhteydessä, sekä millä tavoin nämä menetelmät ovat vaikuttaneet diagnostisen tarkkuuden ja tehokkuuden parantamiseen kliinisessä käytännössä. Tutkimusmenetelmäksi valikoitui kuvaileva kirjallisuuskatsaus, jossa analysoitiin ajankohtaisia tieteellisiä julkaisuja syväoppimisen eläinlääketieteellisistä sovelluksista.

Tutkielmassa havaittiin, että syväoppimismalleja on hyödynnetty muun muassa silmä-, sydän- ja maksasairauksien diagnosoinnissa. Neuroverkkopohjaisilla syväoppimismalleilla analysoidut kuvat ovat osoittaneet parempaa tarkkuutta ja tehokkuutta verrattuna perinteisiin arviointimenetelmiin, mikä on tarkentanut diagnoosia ja hoitoennusteiden arviointia. Tulosten perusteella voidaan todeta, että syväoppimismenetelmien soveltamisen haaste on datan vähäinen määrä ja sen vaihtelu. Mallien siirrettävyys, jatkokoulutusmahdollisuudet, sekä tekstidatan ja kuvantamisen yhdistäminen diagnostiikassa tarjoavat mahdollisuuksia menetelmien soveltamiseen, mutta niiden eettinen ja käytännön soveltaminen vaatii jatkotutkimusta. Tutkimus tarkastelee syväoppimismenetelmien mahdollisuuksia vastata kasvavaan eläinlääkäripalveluiden kysyntään, edellyttäen näiden teknologioiden toimintaperiaatteiden, haasteiden ja eettisten ulottuvuuksien syvällistä ymmärtämistä.

AVAINSANAT: Syväoppiminen, syväoppimismalli, tekoäly, konvoluutioneuroverkot, NLP

Sisällys

1	Johdanto	5
1.1	Tutkimuksen taustaa	5
1.2	Tutkimuksen tarkoitus ja tutkimuskysymykset	6
1.3	Menetelmälliset ratkaisut ja tutkimuksen kulku	8
2	Syväoppimismenetelmät eläinlääketieteessä	9
2.1	Konvoluutioneuroverkot (CNN)	10
2.2	Toistuva neuroverkko (RNN)	12
2.3	Ohjattu, ohjaamaton ja puoliohjattu oppiminen	14
2.4	Siirto-oppiminen	17
3	Syväoppimisen soveltaminen havainnoinnissa ja luokittelussa	18
3.1	Tehokkuuden merkitys eläinlääketieteessä	18
3.2	Havainnointi	19
3.3	Luokittelu	20
4	Syväoppimismallit diagnostiikassa	22
4.1	Syväoppimismallien hyödyntäminen	22
4.2	Syväoppimismallien vs. eläinlääkäreiden suorituskyky	25
4.3	Luonnollisen kielen käsittely (NLP) tautiluokituksessa	26
5	Syväoppimismallien käytön tarkastelu	28
5.1	Syväoppimisen kehitysnäkymiä kuvantamisessa	28
5.2	Käyttöönoton haasteita	29
5.3	Eettisten kysymysten pohdintaa	32
6	Johtopäätökset	37
	Lähteet	41

Kuvat

- Kuva 1. Syväoppimismallien, jotka hyödyntävät CNN-verkkoja, tuloksia (Lähde: Shiri ja muut, 2024, s. 39). 9
- Kuva 2. Esimerkki syväoppimisen toiminnasta: malli luokittelee syötteen ”ankaksi” tai ”ei ankaksi”. (Mukautettu lähteestä Oppermann, 2023). 12
- Kuva 3. Syötteiden arviointiin käytetään sigmoidi- ja hyperbolista tangentti -funktioita (Lähde: Shiri ja muut, 2024, s. 7). 13
- Kuva 4. Esimerkkikuva, jota käytetään syväoppimismallin kouluttamiseen koiran sydämen laajentumisen ennustamisessa. Kuvat A ja C esittää normaalin sydämen koon ja kuvat B ja D esittävät sydämen laajentumisen. Sydämen koon mittaamiseen käytetään VHS-mittausta. (Lähde: Burti ja muut, 2020, s. 4.) 22

1 Johdanto

1.1 Tutkimuksen taustaa

Syväoppimismallien soveltaminen eläinlääketieteeseen avaa mahdollisuuksia tehostaa ja tarkentaa diagnosointia, sekä parantaa jatkohoitojen seuraamista ja niiden ennustetta. Syväoppiminen on Jukka Kolarin ja Aleksi Kallion (2023) mukaan eräs tekoälyn koneoppimismenetelmä, joka hyödyntää neuroverkkoja, jotka rakentuvat useista eri tasoista. Neuroverkot muistuttavat ihmisen monikerroksista kognitiivista järjestelmää (Lee ja muut, 2017, s. 571). Syväoppiminen eroaa muista menetelmistä sen kyvyllä oppia tunnistamaan, tulkitsemaan ja täydentämään kontekstia (Kolari & Kallio, 2023).

Eläinlääketiede on laaja tieteenala, jonka asiantuntijoilla on merkittävä työmäärä. Syväoppimismallien avulla voidaan tehostaa monivaiheisia työtehtäviä, mikä sujuvoittaa tutkimus- ja diagnosointivaiheiden etenemistä ja helpottaa eläinlääkäreiden kognitiivista kuormaa. Eläinlääketieteen useilla eri osa-alueilla on kysyntää uusille teknologioille, mihin syväoppimismalleja hyödyntämällä voitaisiin vastata.

Sähköisten sairauskertomusten tiedonlouhintaprosessiin voidaan tulevaisuudessa integroida syväoppimismalleja, mikä myös säästäisi aikaa olennaiseen tutkimustyöhön ja siten tehostaisi lääketieteen alaa (Pesapane ja muut, 2018, s.5). Applebyn ja muiden (2022, s. 820) mukaan, kuitenkin tällä hetkellä lääketieteellisessä käytettävissä tekoälyjärjestelmiä pidetään kapeina ja heikkoina älykkyyden ja suorituskyvyn osalta, koska ne kykenevät suorittamaan vain tietyn tehtävän.

Radiologian alalla syväoppimisen hyödyntäminen on ollut merkittävää puheentunnistussovelluksissa, joihin kuuluu luonnollisen kielen käsittely ja puheesta tekstiksi -muunnos (Lee ja muut, 2017, s. 574). Laajasti käytetty Dragon-järjestelmä on hyödyllinen automaattisessa litteroinnissa, ja mahdollistaa sanelun ilman sisällön

kirjoittamista itse (Lee ja muut, 2017, s. 579). Lupaavia tuloksia on saatu käyttämällä syviä neuroverkkoja, sekä toistuvia neuroverkkoja, myös sanelun kielen ollessa muu kuin englannin kieli (Lee ja muut, 2017, s. 579).

Lisäksi syväoppimista on hyödynnetty eläinlääketieteen alalla kvantifioinnissa, erityisesti tuotantoeläinten käyttäytymiseen liittyen. Myös karjatuotannossa on hyödynnetty koneoppimismalleja, esimerkiksi tautien havaitsemisessa, käyttäytymisen tunnistamisessa, ympäristöhallitsemisessa, sekä kasvun arvioinnissa (Hennessey ja muut, 2022, s. 855). Esimerkkinä mainittakoon syväoppimiseen perustuva automaattinen tunnistusputkilinja, joka pystyy kvantifioimaan sikatalouden hyvinvointihaasteen, korvanpuremisen esiintymisen. Korvanpureminen voi aiheuttaa bakteeri-infektioita ja heikentää eläinten terveyttä ja hyvinvointia, ja siten heikentää tuottavuutta ja lisätä tarvetta eläinten lääkityksille. (Odo ja muut, 2022.)

Syväoppimismenetelmät eläinlääketieteen alalla parantavat tehokkuutta säästämällä eläinlääkäreiden aikaa esimerkiksi eläinlääketieteellisten raporttien kirjoittamisesta tai niiden kääntämisestä digitaaliseen muotoon. Syväoppimismallien avulla voidaan myös tunnistaa sairauksien merkkejä eläimellä jo ennen ensimmäisten oireiden esiintymistä, mikä voi parantaa hoitomahdollisuuksia, ja jopa pidentää eläimen elinikää. Tässä kandidaatintutkielmassa keskitytäänkin tarkastelemaan syväoppimisen soveltamista pieneläinten diagnostiikassa.

1.2 Tutkimuksen tarkoitus ja tutkimuskysymykset

Tämän tutkielman tarkoitus on tarkastella syväoppimismenetelmien soveltuvuutta pieneläinten diagnostiikkaan, erityisesti kuvantamisen yhteydessä. Näkökulmaksi on valittu diagnostisen tehokkuuden ja tarkkuuden parantaminen eläinlääketieteessä. Näiden tavoitteiden saavuttamiseksi syväoppimismallien käytännön hyötyjä tarkastellaan valikoitujen eläinlääketieteellisten esimerkkien avulla.

Tutkimuksen aihevalinta syntyi henkilökohtaisesta kiinnostuksesta tekoälyn ja syväoppimisen mahdollisuuksiin, ja niiden soveltamismahdollisuuksista eläinlääketieteessä. Kirjallisuuskatsauksen perusteella suomenkielisessä tutkimuskirjallisuudessa on käsitelty niukasti syväoppimisen soveltamista nimenomaan pieneläinten diagnostiikassa. Tutkimuksen rajaus pieneläimiin, erityisesti koiriin ja kissoihin, on perusteltu näiden potilasryhmien yleisyydellä sekä saatavilla olevan datan määrällä. Näin ollen tässä tutkielmassa ei käsitellä tuotanto-, sorkka-, kavio- tai villieläimiä. Tämän tutkielman tarkoitus on osaltaan tuottaa tutkimuskartoitus ja synteesi sellaisesta tulokulmasta, josta sitä ei ole vielä koottu.

Tutkimuksessa pyritään vastaamaan seuraaviin tutkimuskysymyksiin:

1. Miten syväoppimismalleja on hyödynnetty pieneläinten sairauksien diagnostiikassa, erityisesti kuvantamisessa?
2. Millä tavoin menetelmien käyttö on parantanut diagnostista tarkkuutta ja tehokkuutta kliinisessä käytännössä?
3. Mitkä ovat syväoppimismenetelmien soveltamisen haasteet ja mahdollisuudet eläinlääkinnän näkökulmasta?

Tutkimus sijoittuu globaaliin kontekstiin, jossa lemmikkieläinten määrä on kasvussa, ja minkä myötä eläinlääkäripalveluiden kysyntä lisääntyy erityisesti kaupunkialueilla. Tämä kehitys luo tarpeen tehokkaille teknologioille ja diagnostiikkaratkaisuille, jotka ovat skaalautuvia, luotettavia ja eettisesti kestäviä. Syväoppimismenetelmät tarjoavat mahdollisuuden vastata tähän tarpeeseen, mutta se vaatii, että niiden toimintaperiaatteet, luonne ja haasteet ymmärretään. Vain siten syväoppimismenetelmiä voidaan soveltaa tarkoituksenmukaisesti ja maksimoida niiden hyödyt.

1.3 Menetelmälliset ratkaisut ja tutkimuksen kulku

Tässä tutkielmassa käytetty tutkimusmenetelmä on kuvaileva kirjallisuuskatsaus, joka mahdollistaa tutkimusaiheeseen liittyvän kaikkein keskeisemmän ja ajantasaisimman tutkimuksen tarkastelun (Kangasniemi ja muut, 2023). Kuvaileva kirjallisuuskatsaus sopii menetelmäksi myös siksi, että sen avulla eläinlääketieteeseen liittyvä sisältö jäsentyy osaksi syväoppimismallien asiayhteyttä sekä tekniikan tieteenalaa. Valitut tietokannat ovat IEEE Xplore, SciVal, ScienceDirect sekä Web of Science ja käytetty tutkimusaineisto koostuu vertaisarvioituista tieteellisistä artikkeleista. Tärkein tutkimuskirjallisuuden hakuprosessia ohjaava kriteeri on kirjallisuuskatsauksessa käsiteltyjen syväoppimismallien keskeinen rooli pieneläinten diagnostiikassa.

Ensimmäisessä luvussa kuvasin tutkimuksen taustan ja tarkoituksen, sekä tutkimuskysymysten rajauksen. Lisäksi esittelin tutkimuksen metodologisia ratkaisuja. Toisessa luvussa esittelen pieneläinten diagnostiikkaan keskeisimmin liittyvät syväoppimismallit. Kolmannessa luvussa syvennytään syväoppimismallien soveltamiseen havainnoinnin ja luokittelun tehtävissä tehokkuuden ja tarkkuuden näkökulmista. Neljännessä luvussa esittelen systemaattisen kirjallisuuskatsauksen tulokset muodostamalla synteetin syväoppimismallien hyödyntämisestä diagnostisessa kuvantamisessa ja tautiluokituksessa, sekä vertaamalla syväoppimismallien ja eläinlääkäreiden suorituskykyä. Viidennessä luvussa kartoitetaan syväoppimismallien käyttöä, sekä laajennetaan tarkastelua tulevaisuuden näkymiin pieneläinten diagnostiikassa. Luvussa syvennytään myös syväoppimisen käyttöönoton ja eläinlääketieteellisen tekoälyn eettisiin haasteisiin tarkastelemalla yhdeksää eettistä näkökulmaa, jotka ovat olennaisia vastuullisessa eläinlääkärityössä.

2 Syväoppimismenetelmät eläinlääketieteessä

Eläinlääketieteessä käsiteltävä data vaihtelee merkittävästi: se voi koostua vapaamuotoisista tekstitiedostoista tai monimuotoisesta kuvadatasta, kuten kaksi- tai nelidimensionaalisista (2-D, 3-D, 4-D) kuvista (Basran & Appleby, 2022, s. 822). Valittava syväoppimismalli määräytyy käytettävän datan ja käyttötarpeen mukaan (Shiri ja muut, 2024, s. 7). Esimerkiksi tekstipohjaisen aineiston analysointiin käytetään luonnollisen kielen käsittelyn, Natural Language Processing, lyhennettynä NLP, menetelmillä (Basran & Appleby, 2022, s. 822). Konvoluutioneuroverkko, Convolutional Neural Network, lyhennettynä CNN, on sen sijaan tehokas kuvien analysointi- ja luokitteluväline, mikä on saanut erinomaisia tuloksia CNN:ää hyödyntävien mallien suorituskyvystä muun muassa 95–99,88 prosentin tarkkuuksilla (kuva 1.) (Shiri ja muut, 2024, s. 39.)

model	Accuracy %	Precision %	Recall %	F1-Score %	Time (h:m:s)
VGG	94.39	99.79	80.65	89.20	2:17:32
Inception	95.86	96.65	95.14	95.89	0:23:34
ResNet	94.59	95.30	93.64	94.46	1:12:56
InceptionResNet	96.05	97.01	95.36	96.18	0:54:18
Xception	97.38	98.28	96.61	97.44	1:01:11
MobileNet	98.54	98.88	98.28	98.58	0:17:22
DenseNet	98.94	99.12	98.75	98.94	1:10:30
NASNet	96.99	97.69	96.56	97.12	3:50:05

Kuva 1. Syväoppimismallien, jotka hyödyntävät CNN-verkkoja, tuloksia (Lähde: Shiri ja muut, 2024, s. 39).

Syväoppimismallien kouluttamisessa käytetään esiopetusta, joka nopeuttaa mallin oppimisprosessia. Esiopetuksessa malli koulutetaan osittain vastaavalla, aiemmin tunnetulla aineistolla, mikä tehostaa mallin sopeutumista uuteen tehtävään. Esiopetus

perustuu konvoluutioneuroverkkojen ohjattuun oppimiseen, supervised learning, jossa mallille syötetään esimerkkejä syöte–vastauspareista. (Basran ja Appleby, 2022, s. 821.)

2.1 Konvoluutioneuroverkot (CNN)

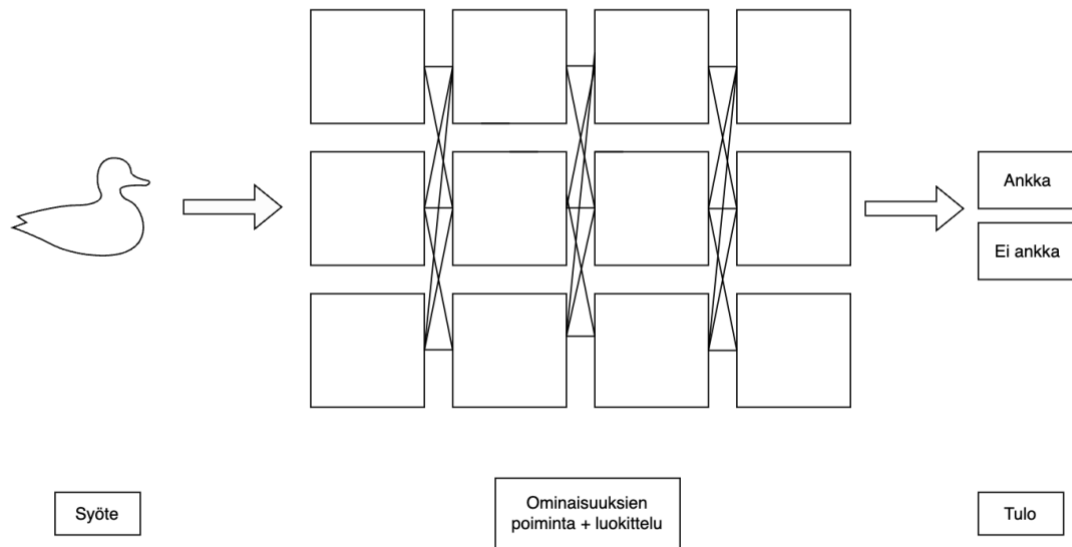
Kimin ja muiden (2019, s. 1) mukaan konvoluutioneuroverkot on rakennettu imitoimaan ihmisen visuaalista prosessia. Lee ja muut (2017, s. 574) sen sijaan esittävät, että konvoluutioneuroverkon oppimisprosessi jäljittelee eläinten näköaivokuoren rakennetta. Pereira ja muut (2023, s. 1) toteavat, että konvoluutioneuroverkko on koulutettu erityisesti kuva-analyysiin. Konvoluutioneuroverkko koostuu konvoluutio-, poolaus-, sekä täysin yhdistetystä kerroksesta (Lee ja muut, 2017, s. 574). Konvoluutiokerros kykenee poimimaan kuvan ominaisuudet, myös sellaiset, jotka eivät ole ihmissilmälle näkyviä (Pesapane ja muut, 2018, s.5). Sen ensisijainen tehtävä on havaita paikallisia, tunnusomaisia piirteitä kuten reunoja, viivoja ja muita visuaalisia elementtejä (Lee ja muut, 2017, s. 574). Heidän mukaansa tämä operaatio jäljittelee visuaalisten piirteiden havaitsemista, kuten näköaivokuoressa tapahtuu. Lee ja muut (2017, s. 575) lisäksi toteavat, että konvoluutiokerros on CNN:n olennaisin komponentti kuvankäsittely tehtävissä, kuten segmentoinnissa ja luokittelussa.

Poolauskerros, engl. pooling layer, tarjoaa kuvan sijaintivarianssiominaisuudet ja vähentää kuvan resoluutiota, joka vähentää laskentaa myöhemmissä kerroksissa, mikä puolestaan vähentää konvoluutiokerroksen laskentakustannuksia (Lee ja muut, 2017, s. 575). Leen ja muiden (2017, s. 575) mukaan ominaisuusmalleja pienennetään yhdistelemällä vierekkäisiä pikseleitä, jotta näkökenttää voitaisiin laajentaa asteittain: tätä toimintoa kutsutaan poolaustoiminnoksi, engl. pooling. He esittävät, että maksimitai keskiarvopoolaus välittää eteenpäin joko suurimman tai keskimääräisen aktivaatioarvon, minkä ansiosta konvoluutiokerrokset muuttuvat vähemmän herkiksi pienille kohdeobjektin siirtymille tai muodonmuutoksille. Poolauskerroksen tehtävä on pienentää ominaisuusmallien dimensioita, jonka lisäksi säilyttää kyky tunnistaa kuvasta

semanttisia piirteitä niiden muodosta ja sijainnista riippumatta (Lee ja muut, 2017, s. 575).

Täysin yhdistetty kerros, Fully Connected Layer tai FC layer, sijaitsee tyypillisesti konvoluutioneuroverkon loppuosassa (Shiri ja muut, 2024, s. 6). Täysin yhdistetyssä kerroksessa neuronit soveltavat lineaarista muunnosta syöttövektoriin painomatriisin kautta, mikä tarkoittaa, että mahdolliset kerrosten väliset yhteydet ovat olemassa ja jokainen tulovektorin tulo vaikuttaa jokaisen lähtövektorin lähtöön (Diego Unzueta, 2025). Jokainen neuroni on siis yhdistetty edellisen kerroksen neuroneihin, mikä noudattaa monikerroksisen perceptron-neuroverkon periaatteita (Panagiotis Antoniadis, 2025; Shiri ja muut, 2024, s. 6). Täysin yhdistetty kerros vastaanottaa syötteen pooling- tai konvoluutiokerroksesta, sekä toimii konvoluutioneuroverkon luokittelijana mahdollistaen verkon tekemät ennusteet (Shiri ja muut, 2024, s. 6).

Kouluttamalla syväoppimismalleja, ne oppivat tunnistamaan sairauksien piirteitä koulutusdatan perusteella 90 prosentin tarkkuudella (Kim ja muut, 2019, s. 6). Mallien kouluttamiseen voidaan käyttää esikäsiteltyjä kuvia, joiden avulla se oppii tunnistamaan piirteitä muun muassa tulehduksista ja niiden vakavuustasosta. Koulutuksen alussa malli oppii yleensä ensin tunnistamaan yksinkertaisia piirteitä, kuten reunoja ja muotoja. Kuvassa 2. on havainnollistava kuva syväoppimismallin toiminnasta. Kouluttamisen myötä mallin suorituskyky kasvaa, ja se oppii tunnistamaan monimutkaisempia piirteitä, kuten esimerkiksi tulehduksellisia alueita. Tämä mahdollistaa syväoppimismallin hyödyntämisen sairauden vakavuuteen liittyvässä arvioinnissa. (Kim ja muut, 2019, s. 2–6.)




Kuva 2. Esimerkki syväoppimisen toiminnasta: malli luokittelee syötteen ”ankaksi” tai ”ei ankaksi”. (Mukautettu lähteestä Oppermann, 2023).

2.2 Toistuva neuroverkko (RNN)

Daniel Nelsonin (2020) mukaan, toistuvat neuroverkot pystyvät käsittelemään peräkkäistä dataa, mikä mahdollistaa mallin sisäisen muistin. Hän esittää, että verkon tulo kopioidaan ja palautetaan verkkoon syötteenä, eli tulo ja syöte ovat silmukassa. Leen ja muiden (2017, s. 575) mukaan, RNN-malli on erikoistunut aikaperusteisen datan, kuten puheen tai käsin kirjoitetun tekstin, käsittelyyn. He esittävät, että yksiköiden väliset yhteydet mahdollistavat verkon sisäisen tilan muodostumisen: tämä antaa verkolle kyvyn mallintaa dynaamista ajallista käyttäytymistä. Nelson (2020), sekä Lee ja muut (2017, s. 575) toteavat, että RNN-verkot pystyvät hyödyntämään ajallista muistia, poiketen tavallisista syöttösuuntaisista verkoista. Tämä siis tarkoittaa, että RNN-verkko huomioi edeltävän syötteen ja säilöo aiemman datan sisällön muistiin. Lee ja muut (2017, s. 575) toteavat, että ajallisen muistin hyödyntäminen mahdollistaa paremman

suorituskyvyn luonnollisen kielen käsittelyssä, tekstin ja puheentunnistuksessa sekä näiden tuottamisessa.

Toistuvan neuroverkon kehittynyt muunnelmä on pitkä lyhytaikainen muistiverkko eli LSTM (Long Short-Term Memory Network), joka on kehitetty ratkaisemaan pitkäaikaisten riippuvuuksien oppimiseen liittyviä haasteita (Shiri ja muut, 2024, s. 8). LSTM huomioi edeltävän syötteen sisällön toistuvan neuroverkon tavoin (Daniel Nelson, 2020). LSTM-mallit koostuvat kolmesta portista: syöteportti, lähtöportti ja unohdeportti, joista kaikilla on tietty tehtävänsä informaation kulun säätelemisessä (Shiri ja muut, 2024, s. 8). Mallin syöteportti on vastuussa syötteen merkittävistä arvoista, jotka päästetään mallin läpi (Daniel Nelson, 2020; Shiri ja muut, 2024, s. 8). Arviointiin portti käyttää hyperbolista tangentti -funktiota (kuva 3.), joka antaa syötteelle arvon välillä $-1 - 1$ (Daniel Nelson, 2020). Syöteportissa käytetty sigmoidifunktio (kuva 3.) määrittää mitkä arvot päästetään verkon läpi: 0 tarkoittaa ei-merkittävää syötettä ja 1 tarkoittaa merkittävää (Daniel Nelson, 2020).



Kuva 3. Syötteiden arviointiin käytetään sigmoidi- ja hyperbolista tangentti -funktioita (Lähde: Shiri ja muut, 2024, s. 7).

Ei-merkittävät syötteet pudotetaan muistista, ja merkittävät säilötään sekä päästetään seuraavalle portille (Daniel Nelson, 2020). Syöteportti määrittää sisäisen tilan päivityksen nykyisen syötteen, sekä aiemman tilan perusteella (Shiri ja muut, 2024, s. 8).

Tulokset siirtyvät unohdeportille, joka arvioi ja pudottaa tarpeettomat syötteet käyttäen sigmoidifunktiota: arvon 0 saaneet syötteet pudotetaan ja arvon 1 saaneet syötteet säilytetään (Shiri ja muut, 2024, s. 8; Daniel Nelson, 2020). Lopuksi syötteet siirtyvät lähtöportille, joka arvioi merkittävät tulot ja muistin tilan käyttämällä hyperbolista tangentti -funktiota (Shiri ja muut, 2024, s. 8; Daniel Nelson, 2020). Lähtöportti säätelee, kuinka paljon sisäinen tila vaikuttaa verkon tuottamaan lähtöön (Shiri ja muut, 2024, s. 8). LSTM-verkon LSTM-kerrokset pystyvät tulkitsemaan peräkkäistä sanadataa, joka etenee yhdistettyihin kerroksiin (Daniel Nelson, 2020).

Suuremmalla koulutusdatalla koulutetut syväoppimismallit tuottavat tarkempia tuloksia kuin pienemmällä koulutusdatalla koulutetut mallit, ja koulutusdatan monipuolisuus parantaa mallin tarkkuutta ja tehokkuutta (Lopez Pineda ja muut, 2019, s. 14). Syväoppimismallit nopeuttavat eläinlääkärien diagnoosityötä tarjoamalla suoraan tarvittavan tiedon potilaasta ilman potilaskertomusten manuaalista läpikäymistä (Lopez Pineda ja muut, 2019, s. 3). LSTM-mallit hyödyntävät skaalautuvaa hierarkkista merkintärakennetta, mikä mahdollistaa potilaiden luokittelun osastoittain, vakavuusasteittain ja hoitoprotokollien mukaisesti (Lopez Pineda ja muut, 2019, s. 2). Tämä lähestymistapa tehostaisi potilaskertomuksien hakua vähentämällä aikaa vievää manuaalista etsimistyötä. Lopez Pinadan ja muiden (2019, s. 14) mukaan, syväoppimismallit pystyvät luokittelemaan automaattisesti lääketieteellisiä potilaskertomuksia ilman asiantuntemusta tai manuaalista ominaisuuksien valintaa. He esittävät, että riittävän koulutusdatan avulla mallit pystyisivät merkitsemään kaikki kliiniset käsitteet riippumatta tietojen syötteestä.

2.3 Ohjattu, ohjaamaton ja puoliohjattu oppiminen

Syväoppiminen on yksi koneoppimisen toteutustavoista, ja sen tarkastelussa on syytä ottaa huomioon koneoppimisen laajempi menetelmäkenttä. Perinteiset

koneoppimismenetelmät, kuten ohjattu ja ohjaamaton oppiminen, ovat edelleen keskeisessä roolissa monilla sovellusalueilla.

Ohjattu oppiminen on eräs koneoppimismalli, jossa algoritmeja koulutetaan valmiilla aineistolla, merkattujen tietoparien, ”tulos” ja ”tuotos”, avulla (SAP, n.d.). Koulutusaineisto koostuu numeerisista tai nimellisistä vektoreista, jotka edustavat syötedatan piirteitä sekä vastaavaa tulosdataa (Lee ja muut, 2017, s. 571). Aineisto siis sisältää oikeiksi luokitellut vastaukset, joiden avulla algoritmi oppii tunnistamaan aineistosta yhtäläisyyksiä ja eroja. Kun tulosdata sisältää jatkuvia arvoja, koulutusprosessia kutsutaan regressioksi, mutta tulosdatan ollessa kategorista, prosessista käytetään nimitystä luokittelu (Lee ja muut, 2017, s. 571). Applebyn ja Basranin (2022, s. 821) mukaan, koulutuksen tuloksena algoritmi kykenee luokittelemaan tietoa ja ennustamaan numeerisia vastauksia itsenäisesti. He toteavat, että ohjattu oppiminen on yleisin koneoppimisen muoto lääketieteessä, sillä se mahdollistaa kliinisesti merkittävän datan tuottamisen.

Ohjaamaton oppiminen on toinen koneoppimismenetelmä, jossa algoritmia koulutetaan ilman valmiiksi merkattua ja jäsennehtyä dataa (SAP, n.d.). Applebyn ja Basranin (2022, s. 821) mukaan algoritmi luo itsenäisesti luokitteluperusteet tutkiessaan syöttödataa ja tunnistaa kaavoja tai rakenteita suurista tietoaaineistoista käyttäen saatavilla olevaa tietoa. Ohjaamaton oppiminen ei ote huomioon tulosdataa, vaan pyrkii löytämään piileviä rakenteita selittämällä syötedataa, joka ei ole nimikoitua (Lee ja muut, 2017, s. 571). Ohjaamaton oppiminen on hyödyllinen suurten aineistojen analysoinnissa, joiden ryhmittelyperusteet eivät ole tiedossa. Lääketieteessä ohjaamattoman oppimisen tavoitteena on löytää datasta kliinisesti merkityksellisiä yhteyksiä. (Appleby & Basran, 2022, s. 821.)

Kolmas koneoppimismalli yhdistää ohjatun ja ohjaamattoman oppimisen piirteitä (Appleby & Basran, 2022, s. 821). Puoliohjattu oppiminen on hyödyllistä tilanteissa, joissa koko aineiston lopputulokset eivät ole tiedossa, kuten diagnoositapauksissa (Appleby & Basran, 2022, s. 821). Mallin kehittämisessä käytetään sekä merkittyä että merkitsemätöntä dataa: rajallinen määrä merkittyjä tietoja auttaa tunnistamaan

laajempia tietojoukkoja. Merkitty tieto toimii oppimisprosessin perustana, mikä nopeuttaa mallin kehittymistä ja parantaa ennustetarkkuutta. Puoliohjattu oppimisalgoritmi analysoi merkittyjen tietojen korrelaatioita, joita hyödynnetään merkitsemättömän datan luokittelussa. (SAP, n.d..)

Edellä käsiteltyjen ohjatun, ohjaamattoman ja puoliohjatun oppimisen lisäksi on olemassa myös yhdistelmäoppimisen (ensemble learning) koneoppimismalli, jossa useiden erilaisten luokittelumenetelmien yhdistelmällä pyritään parantamaan ennustustarkkuutta. Yhdistelmäoppiminen on yleistynyt viime vuosien aikana erityisesti kehittyneemmissä luokittelutehtävissä, joihin algoritmin suorituskyky sopii sen ominaisuuksien ansiosta hyvin. (Lee ja muut, 2017, s. 571.)

Koneoppimismallit ovat olleet merkittävässä roolissa eläinlääketieteen alalla, muun muassa suurien datamäärien keräämisessä ja analysoinnissa, sairauksien seurantatehtävissä ja tautiepidemioiden ennustamisessa (Hennessey ja muut, 2022, s. 855). Pieneläinten kohdalla on hyödynnetty neuroverkkoja esimerkiksi kissojen kroonisen munuaissairauden ennustamiseen 12 kuukauden sisällä 88 prosentin tarkkuudella (Biourge ja muut, 2020, s. 1920), sekä koirien haavaisen sarveiskalvon vakavuusasteen määrittämiseen 90 prosentin tarkkuudella tutkimuskuvien perusteella (Kim ja muut, 2019, s. 6).

Koneoppimisen aluetta, luonnollisen kielen käsittelyä, joka pyrkii tekemään ihmiskielen ymmärrettäväksi koneille, on hyödynnetty potilastietojen kääntämisessä digitaalisiksi dokumenteiksi, sekä digitaalisten dokumenttien etsimisessä yksittäisten avainsanojen tai -lauseiden avulla (Hennessey ja muut, 2022, s. 855).

Zhang ja muut kehittivät ohjatun ja ohjaamattoman oppimisen avulla VetTag-nimisen algoritmin, joka ennustaa eläinlääketieteellisiä diagnosointikoodeja vapaamuotoisista lääketieteellisistä muistiinpanoista (Zhang ja muut, 2019, s. 2).

2.4 Siirto-oppiminen

Siirto-oppiminen on koneoppimisen menetelmä, jossa uusien tehtävien ratkaisemiseen käytetään esikoulutettua lähdemallia (Hosna ja muut, 2022, s. 1). Siirto-oppiminen viittaa kykyyn hyödyntää aiemmin opittua tietoa ja soveltaa sitä uusiin tehtäviin (Banzato ja muut, 2018). Hosnan ja muiden (2022, s. 1) mukaan suurin osa perinteisistä koneoppimisalgoritmeista keskittyy tulevien tulosten ennustamiseen, mikä on hyödyllistä yksittäisissä tehtävissä. He toteavat, että siirto-oppiminen sen sijaan yhdistää tietoa lähteestä ja kohdistaa sen uuteen tehtävään, mikä voi johtaa parempaan ratkaisuun. Siirto-oppimisen avulla voidaan ratkaista haasteita liittyen datan keruuseen ja mallin koulutuksen kustannuksiin, erityisesti lääketieteellisen kuvantamisen tehtävissä (Kucukkara ja muut, 2025).

Eläinlääketieteen alalla siirto-oppimisen avulla koulutetut syväneuroverkkomallit voivat tarjota arvokkaan vaihtoehdon aiemmille tekniikoille eläinlääketieteen sovelluksissa, joissa perinteisillä tekniikoilla olisi rajoittuneisuuksia diagnoosien ja eläinlajien monipuolisuudessa (Banzato ja muut, 2018). Siirto-oppimisen avulla koulutetut konvoluutioneuroverkkomallit tarjoavat tehokkaita tuloksia koirien pään ja niskan alueen kasvainten havaitsemiseen ja tunnistukseen eläinlääketieteen alalla, nopeuttamalla ja tarkentamalla kasvainten paikantamista ja arvioimista automaattisesti (Groendahl ja muut, 2023, s. 1).

Ohjattu siirto-oppimismenetelmä mahdollistaa koirien ruoansulatuskanavan sairauden, PLE:n (Protein-Losing Enteropathy), hoitovasteen ennustamisen yksinomaan ruokavalion perusteella, kun perinteisesti sairauden hoitoon tarvitaan ruokavalion lisäksi immunosuppressiivinen lääkitys (Kathrani ja muut, 2024). Siirto-oppimista hyödyntävät menetelmät mahdollistavat lajien erottelun kuvaluokituksen perusteella tehokkaammin, kuin muut koneoppimismenetelmät (Kucukkara ja muut, 2025).

3 Syväoppimisen soveltaminen havainnoinnissa ja luokittelussa

3.1 Tehokkuuden merkitys eläinlääketieteessä

Syväoppimismallien hyödyntäminen lääketieteellisessä kuvantamisessa vähentää merkittävästi tarvetta manuaaliseen kuvien ja muiden diagnostisten tutkimusten analysointiin, mikä perinteisesti on ollut aikaa vievä prosessi (Pesapane, Codari & Sardanelli, 2018, s.1; Pereira ja muut, 2023, s. 2). Syväoppiminen pystyy käsittelemään suurempaa ja kompleksimpaa datamäärää vastaavalla kustannustehokkuudella verrattuna perinteiseen koneoppimiseen (Xiao ja muut, 2025, s. 2). Tehokkuuden lisäämisen lisäksi syväoppimismallit voivat parantaa eläinten potilasturvallisuutta vähentämällä virheellisten diagnoosien määrää. (Pesapane ja muut, 2018, s. 8.)

Kehitetyt tekoälyjärjestelmät myös tarkastelevat tiettyjä merkittäviä rakenteita, sekä oppivat tunnistamaan kuvien piirteitä, jotka eivät näy ihmissilmälle (Pesapane ja muut, 2018, s. 5). Tällainen lähestymistapa jäljittelee ihmisen analyyttistä kognitiota ja mahdollistaa aiempaa ohjelmistoa paremman suorituskyvyn. Tämän teknologian ansiosta, muun muassa radiologia on nyt siirtymässä objektiivisempaan tieteeseen (Pesapane ja muut, 2018, s.5). Keskeistä on, että tekoälyllä on potentiaali rutiininomaisten havaitsemis-, karakterisointi- ja kvantifiointitehtävien korvaamiseen, mitä radiologit suorittavat kognitiivisia kykyjä käyttäen (Pesapane ja muut, 2018, s. 5). Appleby ja muut (2022, s. 820) huomauttavat, että järjestelmät usein suunnitellaan vain tiettyä tehtävää tai funktiota varten tarkasti.

3.2 Havainnointi

Syväoppimisen konvoluutioneuroverkot kykenevät havaitsemaan muun muassa eläimen rappeutuvia maksasairauksia ultraäänikuvista, sydämen liikakasvua (kardiomegalia) TR-kuvista ja lonkkaniveliön kasvuhäiriön tilan lantion röntgenkuvista (Dumortier ja muut, 2022, s. 2). Kimin ja muiden (2019) mukaan konvoluutioneuroverkkoja käyttävä menetelmä pystyy arvioimaan koirien haavaisen keratiitin, eli sarveiskalvon tulehduksen, vakavuutta. Mallin tehokkuus osoittaa konvoluutioneuroverkkojen hyödyntämisen parantavan eläinlääketieteellistä diagnostiikkaa, sillä se parantaa diagnoosin tarkkuutta ja nopeutta, mikä on hyödyllistä nopeaa hoitoa vaativissa tapauksissa. (Kim ja muut, 2019, s. 1.)

Lääketieteellisen kuvantamisen havainnointia voidaan merkittävästi parantaa tunnistamalla ja analysoimalla kuvien vääristymiä syväoppimisjärjestelmiä hyödyntäen (Caputa ja muut, 2024, s. 1). Tämä tehostaa myös lääketieteellisen kuvantamisen segmentointitehtäviin käytettyjen menetelmien suorituskykyä (Caputa ja muut, 2024, s. 2). Eläinlääketieteessä havainnoinnissa hyödynnetään useita eri syväoppimismenetelmiä, kuten älykkäitä mikroskooppijärjestelmiä (Caputa ja muut, 2024, s. 1).

Perinteisten mallien jatkokehitelmä E-CNN-pohjainen (Enhanced Convolutional Neural Network) superresoluutio tarkoittaa yksisoluanalyysia, mikä on merkittävää sytologisen kuvantamisen kannalta (Caputa ja muut, 2024, s. 3). Superresoluution integroiminen eläinlääketieteelliseen sytologiaan on mahdollistanut visuaalisen havainnoinnin ja segmentointisuorituskyvyn paranemisen (Caputa ja muut, 2024, s. 3). Syväoppimisen laskentatekniikat mahdollistavat diagnostisen tarkkuuden, sekä kuvanlaadun parantamisen älykkäissä mikroskooppijärjestelmissä tulkintaa ja analysointia varten (Caputa ja muut, 2024, s. 3). Konkreettisesti älykäs mikroskooppijärjestelmä voi esimerkiksi korjata virheellisesti asetettuja asetuksia, kuten linssin terävyyttä (Caputa ja muut, 2024, s. 16).

3.3 Luokittelu

Syväoppimismalleja, jotka koulutetaan siirto-oppimisen avulla, voidaan hyödyntää lajien luokittelutehtävissä. Siirto-oppimisen avulla kehitetyt mallit ovat osoittaneet erinomaista suorituskkyä muun muassa tarkkuudessa ja yksityiskohtaisuudessa, mikä on osoittanut syväsiirto-oppimismallien tarjoavan tehokkaita luokittelutuloksia. Siirto-oppimisen avulla koulutettuja syväoppimismalleja voidaan myös mukauttaa jo olemassa olevaa mallia uusiin tietokokonaisuuksiin. Tämä tapahtuu lisäämällä aineistoon kuvia uusista lajeista ja lisätiedon keräämisellä. Mallin mukauttamismahdollisuuden myötä siirto-oppimisella koulutettuja syväoppimismalleja voidaan hyödyntää laajemmin eri osa-alueilla, minkä lisäksi mallin tarkkuus ja suorituskky kasvaa. (Kucukkara ja muut, 2025.)

Naiivi Bayes -malli, joka perustuu syötedatan todennäköisyysjakaumaan, on yksi tavallisimmista luokittelualgoritmeista. Kyseinen menetelmä on laskennallisesti kevyt ja rakenteeltaan yksinkertainen, se voi silti saavuttaa erinomaisia tuloksia tietyissä sovelluskohteissa, kuten rRNA sekvenssien luokittelussa. Yksi suosituin luokittelualgoritmi on tukivektorikone, SVM, joka sijoittuu usein korkeimmalle luokitteluongelmien suorituskkymittauksissa. (Lee ja muut, 2017, s. 571.)

Tukivektorikoneen tärkein ominaisuus on kyky hyödyntää regularisointia ja konveksia optimointia. Regularisointi auttaa estämään ylisopeutumista eli estää mallia oppimasta koulutusdataa liian yksityiskohtaisesti, ja yleistä opitun tiedon uuden datan luomiseen. Konvekssi optimointi varmistaa mallin oppimisprosessin matemaattisuuden ja vakauden, minkä myötä algoritmi löytää parhaan mahdollisen ratkaisun jäämättä väärään kohtaan. Kehittyneemmissä luokittelutehtävissä on alettu hyödyntämään yhdistelmäoppimista, sillä sen ominaisuudet mahdollistavat ennustustarkkuuden parantamisen. (Lee ja muut, 2017, s. 571.)

Konvoluutioneuroverkkomallit ovat tehokkaita koiran lääketieteellisten kuvien luokitteluongelmissa, sillä konvoluutioneuroverkko kykenee muun muassa


luokittelemaan joko pinnalliset tai syvät sarveiskalvon haavaumat valokuvista, sekä lonkan dysplasiastatuksen lantion röntgenkuvista (Dumortier ja muut, 2022, s. 2).

Syväoppiminen mahdollistaa solukuva-analysoimisen automatisoinnin tunnistamalla ja luokittelemalla poikkeavuuksia samalla tarkentaen ja nopeuttaen eläinlääkäreiden diagnostisia tuloksia (Caputa ja muut, 2024, s. 1).

4 Syväoppimismallit diagnostiikassa

4.1 Syväoppimismallien hyödyntäminen

Syväoppimismallia voi hyödyntää koirien sydämen laajentumisen (kardiomegalia) havaitsemisessa rintaontelon röntgenkuvista. Sydämen laajentuminen ja muut sydänsairaudet ovat koirien yleisimpiä kuolemansyitä. Syväoppimismallia koiran sydämen laajentumisen tunnistamiseen koulutetaan ja testataan laajalla tietokannalla, joka sisältää koirien rintakehän röntgenkuvia. Rintakehän röntgenkuvista voidaan arvioida koiran sydämen koko VHS (vertebal heart scale) -menetelmän avulla. (Burti ja muut, 2020, s. 2.)



Kuva 4. Esimerkkikuva, jota käytetään syväoppimismallin kouluttamiseen koiran sydämen laajentumisen ennustamisessa. Kuvat A ja C esittää normaalin sydämen koon ja kuvat B ja D esittävät sydämen laajentumisen. Sydämen koon mittaamiseen käytetään VHS-mittausta. (Lähde: Burti ja muut, 2020, s. 4.)

Menetelmässä mitataan sydämen ääriiviivat käyttäen nikamavartalon pituuksia. Tietokanta sisältää kahdenlaisia röntgenkuvia, joista esimerkki kuvassa 4.: VHS-Kardiomegalia (kardiomegaliaa osoittavat kuvat) ja Ei-VHS-Kardiomegalia (kuvat, joissa ei ollut kardiomegaliaa). Tietokannan kuvat luokitellaan eläinlääkärien toimesta ennen konvoluutioneuroverkkomallien koulutusta. Kvanttunnistustehtävissä tehokkaat konvoluutioneuroverkot mahdollistavat syväoppimismallin tunnistamaan sydämen suurentumisen merkit koiran röntgenkuvissa. (Burti ja muut, 2020, s. 3.)

Syväoppimismenetelmät ovat muodostuneet keskeisiksi työkaluiksi monilla sovellusalueilla eläinlääketieteessä, erityisesti kuvantamisessa, luonnollisen kielen prosessoinnissa sekä havainnoinnissa. Taulukossa 1 on esitetty eläinlääketieteen keskeisimmät syväoppimismallit, joita sovelletaan alalla jatkuvasti laajemmin, sekä niiden käyttötarkoitus, hyödyt ja suorituskyky.

Taulukko 1. Yhteenveto syväoppimismalleista ja niiden hyödyntämisestä

Mallityyppi	Käyttötarkoitus/ Sovelluskohde	Hyödyt ja suorituskyky	Lähde
CNN, Konvoluutioneuroverkko	Kuvantaminen: sydänsairaudet, keratiitti, lonkkien ja maksan arviointi	Parantaa diagnoosin tarkkuutta ja nopeutta, tunnistaa myös ei-näkyviä piirteitä	Burti ja muut, 2020; Kim ja muut, 2019; Dumortier ja muut, 2022
Toistuva neuroverkko, RNN / LSTM	NLP: tautikoodien ennustaminen eläinlääkäriin muistiinpanoista	Käsittelee sekventiaalista dataa, mahdollistaa potilaskertomusten automaattisen luokittelun	Lopez Pineda ja muut, 2019; Nie ja muut, 2018
Ohjattu oppiminen	Kuvien ja tekstien luokittelu, diagnostiikka	Korkea tarkkuus opetetulla aineistolla, yleisin menetelmä kliinisissä tehtävissä	Appleby & Basran, 2022
Ohjaamaton oppiminen	Piirteiden tunnistus datasta, kun luokkia ei ole ennalta määritelty	Tunnistaa rakenteita suurista aineistoista ilman ihmisen tekemää luokittelua	Appleby & Basran, 2022

Puoliohjattu oppiminen	Diagnoositalanteet, joissa osa datasta on merkitsemätöntä	Hyödyntää osittain merkittyä dataa → nopeuttaa oppimista ja parantaa tarkkuutta	Appleby & Basran, 2022
Siirto-oppiminen	Harvinaiset sairaudet, lajitunnistus, hoitovasteen arviointi	Säästää koulutusaikaa, mahdollistaa hyvät tulokset pienellä datalla; sovellettavissa uusiin kohteisiin	Kathrani ja muut, 2024; Groendahl ja muut, 2023; Kucukkara ja muut, 2025

Konvoluutioneuroverkot ovat tehokkaita kuvapohjaisessa analytiikassa, kuten sairauksien diagnosoinnissa radiologisten kuvien perusteella. Ne kykenevät tunnistamaan myös yksityiskohtaisia, ei-ilmeisiä kuvapiirteitä, mikä voi olla tukena eläinlääkärin arvioinnissa, ja täten parantaa diagnoosin tarkkuutta ja prosessin nopeutta. (Burti ja muut, 2020; Kim ja muut, 2019; Dumortier ja muut, 2022).

Toistuvat neuroverkot ja niiden kehittyneemmät muodot, kuten pitkäaikaismuistiin perustuvat LSTM-verkot, soveltuvat ajallisesti jäsenyvän ja sekventiaalisen datan, kuten potilaskertomusten, käsittelyyn. Näillä menetelmillä on saavutettu tuloksia esimerkiksi tautiluokitusten automaattisessa ennustamisessa. (Lopez-Pineda ja muut, 2019; Nie ja muut, 2018).

Ohjattu oppiminen on laajimmin käytetty menetelmä kliinisessä kontekstissa, koska se tarjoaa korkean tarkkuuden riittävällä määrällä merkittyä dataa. Ohjaamaton ja puoliohjattu oppiminen puolestaan sopii luokittelemattoman tai osittain luokitellun datan käsittelyyn. Näiden menetelmien vahvuus on tunnistaa piirteitä ja rakenteita datasta ilman luokittelua, mikä tekee niistä hyödyllisen työkalun tutkimusvaiheisiin tai alustavien analyysien laatimiseen. Puoliohjattu oppiminen, joissa yhdistyy ohjatun ja ohjaamattoman oppimisen ominaisuudet, mahdollistaa mallin kouluttamisen myös osittain merkittyjen aineistojen avulla. (Appleby & Basran, 2022).

Siirto-oppiminen on tehokas työkalu, kun koulutusdataa ei ole tarpeeksi tai se on vaikeasti saatavilla, kuten esimerkiksi harvinaisten sairauksien tunnistamisessa. Siirto-oppimisessa hyödynnetään valmiiksi koulutettuja malleja ja mukautetaan niitä

kontekstin mukaan. Tämä vähentää koulutusresurssien tarvetta ja mahdollistaa hyvän suorituskyvyn pienemmilläkin aineistoilla. (Kathrani ja muut, 2024; Groendahl ja muut, 2023; Kucukkara ja muut, 2025).

Syväoppimismallit mahdollistavat eläinlääketieteellisen sytologian prosessin tehostamisen, mikä perinteisesti vaatii alan ammattilaisen tutkimaan lukuisia solunäytteitä mikroskoopin alla. Tekoälyn automatisointi parantaa eläinlääkintähoidon tehokkuutta ja diagnoosien, sekä hoidontarpeen tarkkuutta. (Caputa ja muut, 2024, s. 1).

4.2 Syväoppimismallien vs. eläinlääkäreiden suorituskyky

Syväoppimismallien suorituskykyä on verrattu eläinlääkäreiden tekemiin diagnooseihin muun muassa koirien sydämen suurentumisen (kardiomegalia) havaitsemisessa rintaontelon röntgenkuvista. Burti ja muut (2020, s. 5) osoittivat, että konvoluutioneuroverkkoa hyödyntävä syväoppimismalli kykenee tunnistamaan sydämen laajentumisen merkit tehokkaasti, jopa sellaisissa tilanteissa, joissa ihmisen tekemä arvio voi olla epävarma tai virhealtis. Syväoppimismallit pystyvät siis erottamaan sydämen laajentumisen koirien röntgenkuvista suurella vastaavuudella ja Burti ja muut (2020, s. 5) esittävätkin, että mallien herkkyys ja tarkkuus on verrattavissa eläinlääkäreiden antamiin arvioihin.

Myös Dumontier ja muut (2022, s. 2) tuovat esiin, että syväoppimiseen perustuvat konvoluutiomallit ovat osoittaneet vastaavaa ja jopa parempaa tehokkuutta arvioimaan koirien sydämien kammioiden ja vasemman eteisen laajentumista TR-kuvista verrattuna eläinlääkäreihin. Havainnoimisen lisäksi syväoppimismallin algoritmi pystyy analysoimaan röntgenkuvia johdonmukaisesti, ilman ihmisen tekemälle tulkinnalle tyypillistä arviointiin liittyvää vaihtelua (Burti ja muut, 2020, 2–5).

Sydänsairauksia diagnosoidessa rintakehän röntgenkuvaus on menetelmä, jonka tulkinta vaatii kokemusta. Eläinlääketieteessä radiologian erikoislääkärien määrä on rajallinen, eikä useimmilla klinikoilla ole erikoistuneita radiologeja saatavilla, minkä takia

kuvien arviointi voi jäädä yleiseläinlääkäreiden vastuulle. Näissä tilanteissa, erityisesti kiireellisissä tapauksissa, syväoppimisalgoritmit voivat toimia tukityökaluina, jotka lisäävät tulkintojen tarkkuutta ja vähentävät inhimillisiä virheitä. (Burti ja muut, 2020, s. 1)

Vertailtaessa syväoppimismallien arvioinnin tuloksia on verrattu eläinlääkäreiden antamiin arvioihin, mitkä ovat osoittaneet mallin kyvykkyyden tunnistaa sairauksien merkit tehokkaasti. Syväoppimismalli tunnistaa esimerkiksi keratiitin piirteet myös silloin, kun sairaus on vaikeasti havaittavissa. Syväoppimismallin ansiosta sairauden hoitamisen tarkkailu on parantunut konvoluutiomallin ansiosta, sillä mallin kyky arvioida silmäkuvista tapahtuvia muutoksia hoidon aikana on osoittanut tarkkuutta. Konvoluutiomallin on todettu pystyvän edesauttamaan koirien silmänsairauden diagnosointia ja hoitamista, tarkentamalla ja nopeuttamalla diagnosointiprosessia. (Kim ja muut, 2019, s. 6)

Kliininen koodaus eläinlääketieteessä on lähes olematonta riippuen klinikasta, sillä eläinlääkäreillä ei ole kannustimia koodien laatimiseen potilaskertomuksissa (Lopez-Pineda ja muut, 2022, s. 2). Lopez-Pinedan ja muiden (2022, s. 2) mukaan, tilannetta heikentää maksajajärjestelmien ja lainsäädännön puute. He esittävät, että esimerkiksi laskutuskoodit eivät ole yhteneviä eläinlääketieteellisten yksiköiden välillä.

4.3 Luonnollisen kielen käsittely (NLP) tautiluokituksessa

Syväoppimismalleja sovelletaan monipuolisesti eri toimialoilla. Keskeisimpiä sovelluskohteita ovat kuvan- ja puheentunnistus, NLP (Natural Language Processing) eli luonnollisen kielen käsittely, sekä autonomiset järjestelmät. Eläinlääketieteessä NLP-tekniikat mahdollistavat potilastietojen automaattisen tulkinnan. Syväoppimista voidaan hyödyntää tautikoodien ennustamisessa, missä LSTM-algoritmi saa syötteenä eläinlääkärin vapaamuotoiset muistiinpanot. Koodin tarkkuus ja algoritmin suorituskyky riippuu muun muassa koulutusdatan määrästä, laadusta ja monimuotoisuudesta. Vaikka suurilla ja monipuolisilla aineistoilla voidaan saavuttaa hyviä tuloksia, tiettyjen

monimuotoisten sairauksien, kuten ruoansulatuselimistöjen sairauksien, tautikoodien ennustaminen on edelleen haasteellista. (Nie ja muut, 2018)

Luonnollisen kielen käsittelyn avulla voidaan automatisoida manuaalista tiedonhakuja ja raportointia, mikä nopeuttaa diagnoosiprosessia ja vähentää tulkinnanvaraisuutta. Tällaiset sovellukset tukevat erityisesti kiireisessä eläinlääkärityössä tehtävää päätöksentekoa, jossa tarkka ja ajantasainen tieto on olennaista.

Lopez Pinedan ja muiden (2019, s. 14) tutkimuksessa kehitettiin järjestelmä, joka voi tunnistaa ja merkitä kliinisiä koodeja potilasyhteenvedoista. Järjestelmää varten valittiin toistuvan neuroverkon pitkä lyhytaikainen muistiverkko sen silmukkaominaisuuden perusteella. Tutkimuksen syötteet koostuvat sanaupotuksista (embeddings), joissa yksittäiset sanat muunnetaan numeerisiksi vektoreiksi kliinisistä kertomuksista. Sanaupotukset oppivat sanan vektoritilan esityksen siten, että kontekstiltään samankaltaiset sanat sijoittuvat lähelle toisiaan vektoritilassa, sekä tallentavat koko koulutusdatan globaalit tilastolliset ominaisuudet. (Lopez Pineda ja muut, 2019, s. 7).

5 Syväoppimismallien käytön tarkastelu

5.1 Syväoppimisen kehitysnäkymiä kuvantamisessa

Syväoppimista hyödynnetään yhä useammilla aloilla, erityisesti lääketieteessä ja eläinlääketieteessä. Laskentatehojen kehittyminen, erityisesti syväoppimissirujen osalta, on mahdollistanut yhä monimutkaisempien mallien kouluttamisen ja ajamisen kustannustehokkaasti. Tämän ohella laitteiston hinnat ovat laskeneet, mikä on madaltanut kynnystä mallien käyttöönotolle. (Guo ja muut, 2015.)

Yksi merkittävimmistä edistysaskeleista tekoälyn soveltamisessa on syväoppimismallien kyky tulkita lääketieteellistä kuvadataa. Kvanttulkinnan ja -analysoinnin tehokkuus ei perustu pelkästään mahdollisuuteen käyttää parempaa tietokonetehoa (Pereira ja muut, 2023, s. 2), vaan myös mallien kouluttamiseen suurilla ja laadukkailla aineistoilla, jotka koostuvat tutkimuksista ja monipuolisista eläinlääketieteellisistä kuvista. Algoritmeille syötetään lääketieteellistä dataa tarkasteltavaksi, minkä myötä ne oppivat tunnistamaan toistuvia piirteitä ja yhdistämään ne tiettyihin lopputuloksiin.

Kvanttamisessa syväoppimismetodit voivat automatisoida subjektiivista ja monimutkaista kuvien analysointiprosessia, mikä sujuvoittaisi ja tehostaisi kuvantamista (Pereira ja muut, 2023, s. 1). Mallien suorituskyky on riippuvainen kouluttamisen määrästä ja datan monipuolisuudesta: parempi suorituskyky mahdollistaa vaativampien diagnostisten tehtävien suorittamisen. (Pesapane, Codari & Sardanelli, 2018). Syväoppimismalleja voidaan myös hienosäätää käyttämällä aiemmin luotuja CNN-malleja, jotka on koulutettu julkisten kuvapankkien aineistolla (Kim ja muut, 2019, s. 6).

Tulevaisuudessa syväoppimisen ansiosta voidaan taata entistä tarkempaa, nopeampaa ja johdonmukaisempaa kuvantulkintaa, mikä voi vähentää myös inhimillisiä virheitä ja vapauttaa asiantuntijoita rutiinistyöstä vaativiin tehtäviin. Tämä kehitys tukee diagnostiikan kehittymistä datapainotteisemmaksi ja se voi lisätä potilasturvallisuutta myös eläinlääketieteessä.

Lääketieteellisen kuvantamisen tekoälyyn ja koneoppimiseen perustuvaa järjestelmää, CAD, Computer-Aided Detection, on käytetty muun muassa röntgen-, MRI- tai CT-kuvissa. Se on lääkäreiden tukityökalu havaitsemaan poikkeavuuksia ja arvioimaan sairauksien vakavuutta. Toinen työkalu on PACS, Picture Archiving and Communication System -järjestelmä, joka taltioi ja arkistoi lääketieteellisiä kuvia, ja sen kautta voi jakaa kuvia eri työasemille ja laitoksille. CAD- ja PACS-järjestelmät yhdessä ovat mahdollistaneet radiologien työn tehostamisen, sillä ne ehdottavat radiologeille automaattisesti ehdotuksia löydöksistä. (Dubey & Hanmandlu, 2012.)

Lee ja muut (2017, s. 571) esittävät, että järjestelmät eivät ole enää suorituskyvyltään tarpeeksi tehokkaita laajamittaiseen käyttöön kliinisessä arjessa, minkä lisäksi järjestelmiä rajoittaa niiden herkkyys kuvantamisprotokollien ja kuvamelun vaihtelulle. Heidän mukaansa syväoppimisen avulla CAD-järjestelmiä voidaan kuitenkin parantaa kliiniseen käyttöön soveltuvalle tasolle, sillä syväoppimisella on siihen sopivia ominaisuuksia, muun muassa joustavuus kuvamelua ja kuvantamisprotokollien vaihtelua kohtaan. Lee ja muut (2017, s. 571) toteavat myös, että siirto-oppiminen ja sen ainulaatuisuus voisi nopeuttaa CAD-järjestelmien kehitystä eri sairauksiin ja kuvantamismenetelmiin.

5.2 Käyttönoton haasteita

Eräitä syväoppimisen haasteita ovat riippuvuus koulutusdatan laadusta ja määrästä, sekä taipumus ylisovittamiseen, engl. overfitting (Lee ja muut, 2017, s. 580). Ylisovittaminen tarkoittaa koneoppimisen alalla sitä, kun malli mukautuu liian tarkasti tiettyyn aineistoon, eikä kykene yleistämään oppimaansa uusille tasoille (Pereira ja muut, 2023, s. 4). Pereira ja muut (2023, s. 3) esittävät, että malli oppii tällaisessa tilanteessa myös koulutusaineiston kohinaa, johon kuuluu suorituskapasiteettia, mikä puolestaan heikentää suorituskykyä sen opetellessa uusia aineistoja. Heidän mukaansa ylioppimisen välttämiseksi voidaan tehdä tiettyjä toimenpiteitä, kuten jakaa aineistoa

osiin, välttää liiallista iterointia keskeyttämällä harjoittelu, käyttää dropout-tekniikkaa tai käyttää suurta aineistoa.

Pereira ja muut (2023, s.3) toteavatkin, että mahdollisimman suuri aineisto vähentää ylioppimisen esiintyvyyttä, sillä pienillä aineistoilla kouluttaminen on johtanut ylioppimiseen. Lääketieteellisen kuvantamisen datan määrä on merkittävän pieni, mikä aiheuttaa haasteita syväoppimisen kehittämisessä ja kouluttamisessa (Dumortier ja muut, 2022, s. 7). Kun aineistoa on rajallinen määrä, voidaan aineiston kokoa kasvattaa keinotekoisesti argumentointitekniikalla, jossa sitä muokataan säilyttäen alkuperäinen luokitus (Pereira ja muut, 2023, s. 3). Pereiran ja muiden (2023, s. 3) mukaan, kuvia voidaan muun muassa sumentaa, kiertää, zoomata tai rajata. Kim ja muut (2019, s. 6) kuitenkin esittävät, että koulutusaineiston kuvien rajaaminen ja muu muokkaaminen täytyy tehdä mallin ominaisuudet huomioiden, koska muutokset voivat vaikuttaa mallin suoritus- ja toimintakykyyn.

Radiologien työnkuva keskittyy ensisijaisesti lääketieteellisten kuvien analysointiin, mutta samalla heidän työmääränsä on kasvanut merkittävästi. Koska kuvantamisanalyysi on aikaa vievää, eikä radiologeilla ole aina mahdollisuutta arvioida yksittäisten löydösten kliinistä merkitystä kokonaisvaltaisesti. Lisäksi radiologit eivät tyypillisesti osallistu eläinlääketieteen kliiniseen tutkimustyöhön tai potilaan muuhun hoitoon, jolloin heillä ei ole kattavaa kliinistä kontekstia, kuten oireita tai laboratoriotuloksia. (Pesapane, Codari & Sardanelli, 2018).

Tämä voi johtaa tilanteisiin, joissa esimerkiksi röntgenkuvassa havaittu varjostuma jää vaille tarkempaa tulkintaa. Tällöin yleiseläinlääkäreiden vastuulle jää kliininen päätöksenteko, vaikka heidän asiantuntemuksensa kuvantamisdiagnostiikasta ei välttämättä ole yhtä syvällistä kuin erikoistuneen radiologin. Tämä lisää väärin diagnoosien riskiä, sillä kaikki kuvantamisessa havaitut poikkeavuudet eivät ole patologisia eivätkä aina vaadi jatkotoimenpiteitä. (Pesapane, Codari & Sardanelli, 2018).

Lee ja muut (2017, s. 580) esittävät, että uusien arviointimenetelmien kehittäminen on tärkeää, jotta tekniikoiden suorituskyky voidaan mitata luotettavasti. Heidän mukaansa

käyttökelpoisuuden varmistamista varjostavia asioita ovat muun muassa sairauksien esiintyvyyden vaihtelut, kuvantamislaitteiden erilaisuus, sekä käytössä olevat kuvantamisprotokollat, jotka vaihtelevat globaalisti.

Monikerroksisten syväverkkojen black box -testauksessa esiintyvien piilokerrosten kasvava määrä vaatii suurempaa laskentatehoa (Pereira ja muut, 2023, s. 3). Syväverkkojen syvimmissä kerroksissa esiintyy piilokerroksia, joiden logiikkaa ja tulkintaa ei voida perustella niiden kompleksisuuden takia, mikä heikentää niiden ymmärtämistä (Pereira ja muut, 2023, s. 3). Pereira ja muut (2023, s. 3) esittävät, että jokainen solmu ensimmäisessä piilokerroksessa etsii jotain tiettyä syötekerroksesta, mutta mitä syvemmälle kerroksissa mennään, sitä abstraktimmiksi ja monimutkaisemmiksi komponentit muuttuvat.

Leen ja muiden (2017, s. 580) mukaan, syväoppimismenetelmien black box -luonne on huolta herättävä asia, vaikka menetelmät tuottaisivat erinomaisia tuloksia. He toteavat, että koska syväoppimisjärjestelmien kaupallinen kehitys riippuu kliinisten kuvantamistietojen käytöstä ja datan laadusta, se voi herättää eettisiä sekä oikeudellisia kysymyksiä. Lee ja muut (2017, s. 580) huomauttavat myös järjestelmien epätäydellisyyksistä: kenen vastuulla on virheet tai väärät tulkinnat, jotka johtavat pahimmassa tapauksessa potilaan vahingoittumiseen?

Syväoppimismallien käyttöönotto voi osaltaan lievittää näitä haasteita tarjoamalla objektiivista tukea kuvien tulkintaan. Kuitenkin järjestelmien integroimiseksi osaksi kliinistä päätöksentekoa, tarvitaan huolellista testausta, validointia ja koulutusta. Mallien kehityksessä on tärkeää huomioida kliinisen tiedon yhdistäminen kuvadataan, jotta diagnoosit voidaan tehdä kokonaisvaltaisemmin ja yksilöllisemmin. Vaikka syväoppimisen sovelluksia lääketieteellisessä kuvantamisessa on tutkittu laajasti, tiettyjen diagnoosialueiden, kuten silmätautidiagnostiikan kohdalla menetelmien käyttö on ollut hyvin rajallista (Kim ja muut, 2019, s. 2). Kim ja muut (2019, s. 2) huomauttavat heidän tutkimuksensa olevan ensimmäinen syväoppimista hyödyntävä koirien sarveiskalvon vakavuuden arvioinnissa, mikä osoittaa tekoälyratkaisujen olevan vielä vähäistä tietyillä erikoisaloilla.

5.3 Eettisten kysymysten pohdintaa

Tässä kandidaatintutkielmassa käsiteltyjen syväoppimismallien soveltamiseen liittyviä eettisiä kysymyksiä on syytä tarkastella myös eläinlääketieteen näkökulmasta. Tekoälyn eettisiin ohjeisiin kuuluu viisi peruseriaa: läpinäkyvyys, oikeudenmukaisuus ja tasapuolisuus, vahingon välttäminen, vastuullisuus ja yksityisyys (Jobin ja muut, 2019). Lemmikkieläimet ovat kuitenkin huomattavasti alttiimpia tekoälyn aiheuttamille haittavaikutuksille kuin ihmiset, sillä niillä ei ole yhtä vahvaa sosiaalista, moraalista tai oikeudellista asemaa (Coghlan & Quinn, 2024). Coghlan ja Quinn (2024) esittävät, että lainsäädäntö ei suojaa eläimiä vammauttamiselta tai asiakkailta, jotka vaativat perusteetonta eutanasiaa. He toteavat, että eläinlääketieteessä käytettävän tekoälyn merkittävimmät, haastavimmat ja eettisesti seurauksellisimmat kysymykset liittyvät diagnosoimiseen, ennusteiden arviointiin ja hoitopäätöksiin.

Coghlan ja Quinn (2024, s. 2339) ovat koonneet eläinlääketieteelliselle tekoälylle yhdeksän näkökulmaa, jotka ohjeistavat eläinlääkäreitä käyttämään ja soveltamaan tekoälyä eettisesti. Seuraavaksi pyrin tunnistamaan kunkin eettisen näkökulman osalta ratkaisut, joilla tekoälyn käyttöä voidaan ohjata vastuullisesti eläinlääketieteellisessä kontekstissa.

Tarkkuus ja luotettavuus. Tekoälyn tarkkuus ja luotettavuus on olennaista eläinlääketieteen, patologian, radiografian ja kirurgian aloilla, sillä se voi poistaa inhimillisiä ennakkoluuloja ja arviointivirheitä (Coghlan & Quinn, 2024, s. 2339). Epätarkka tekoäly voi aiheuttaa vääriä diagnooseja tai huonoja hoitosuosituksia, mikä voi vahingoittaa potilaita (Coghlan & Quinn, 2024, s. 2340). Coghlan ja Quinn (2024, s. 2340) huomauttavat, että tekoälyjen tarkkuus testiaineistolla arvioituna ei takaa kliinisen käytön luotettavuutta. Heidän mukaansa tällainen tilanne voi ilmaantua, jos koulutus- ja testiaineistot eivät edusta todellista käyttötapausta tai sisältävät vääristymiä. Samankaltainen haaste esiintyy eteläisellä pallonpuoliskolla käytettäessä eläinlääketieteellistä tekoälyä, joka on kehitetty pohjoisella pallonpuoliskolla.

Edustavalla datalla koulutettu ja arvioitu sekä tarkaksi osoittautunut tekoäly ei takaa parempia kliinisiä lopputuloksia (Coghlan & Quinn, 2024, s. 2340). Myös Kim ja muut (2019, s. 2) huomauttavat, ettei tekoälyä ole vielä kunnolla tutkittu tästä näkökulmasta, vaikka eläinlääketieteellisen tekoälyn käyttöön liittyen on havaittavissa kasvavaa kiinnostusta. Coghlan ja Quinn (2024, s. 2340) toteavat, että osa tekoälyratkaisuista on virheellisiä, kuten ihmisen ilmeitä diagnosoiva tekoäly, johon kohdistuva kritiikki keskittyy ristiriitaan tunteiden ja ilmeiden keskinäisyyden välillä. Eläinten tunnetilojen ja kivun havaitsemiseen sekä hyvinvointiin suunnattuihin tekoälyihin liittyy samankaltaista virheellisyyttä (Coghlan & Quinn, 2024, s. 2340).

Ylidiagnosointi. Ylidiagnosoinnilla tarkoitetaan ei-haitallisten sairauksien tai tilojen diagnosoimista, esimerkiksi tekoäly voi tunnistaa vaarattoman luuston poikkeavuuden (Coghlan & Quinn, 2024, s. 2340). Eräs merkittävin aiheuttaja ylidiagnosoinnille on Coghlanin ja Quinin (2024, s. 2340) mukaan laajamittaiset seulontaohjelmat, joita toteutetaan terveille yksilöille. He huomauttavat, että ylidiagnosointi on sivuutettu, mutta yleistyvä huolenaihe, joka voi johtaa tarpeettomiin lisätutkimuksiin ja -hoitoihin.

Eläinlääketieteellinen tekoäly voi Coghlanin ja Quinin (2024, s. 2340) mukaan lisätä ylidiagnosoinnin riskiä ja esiintyvyyttä. He esittävät, että varovaisempaan lääketieteeseen kannustaminen voisi olla yksi syy ylidiagnosoinnin laajemmalle esiintyvyydelle. He toteavat, että siksi on tärkeää oppia tunnistamaan ja estämään tekoälypohjaista ylidiagnosointia.

Läpinäkyvyys. Eläinlääketieteessä läpinäkyvyydellä tarkoitetaan käyttäjän tietoisuutta tekoälyjärjestelmän laatiman ennusteen prosessista (Coghlan & Quinn, 2024, s. 2341). Lee ja muut (2017, s. 580) esittävät, että syvissä neuroverkoissa monimutkaisten black box -mallien ennusteiden taustalla olevat syyt voivat olla tuntemattomia. Tämä voi Coghlanin ja Quinin (2024, s. 2341) mukaan aiheuttaa ristiriitoja suorituskyvyn ja ymmärrettävyyden välillä, sillä parempi suoritus voi tarkoittaa heikkoa läpinäkyvyyttä. Toisaalta he esittävät, etteivät kaikki pidä black box -malleja ongelmallisena niiden tarkkuuden ansiosta. Koska läpinäkymättömyys vaikeuttaa virheiden ja ennustevirheiden havaitsemista, black box -mallit voidaan tarvittaessa korvata virheitä

helpommin paljastavilla, joskin epätarkemmilla malleilla (Coghlan & Quinn, 2024, s. 2341).

Kaupallisten toimijoiden keskuudessa esiintyvää järjestelmien toimintalogiikan salailua kilpailijoilta ja käyttäjiltä pidetään myös haitallisena, koska se voi heikentää läpinäkyvyyttä (Coghlan & Quinn, 2024, s. 2341). Coghlan ja Quinn (2024, s. 2341) toteavat, etteivät kaikki perehdy syvällisesti avoimiin malleihin, vaikka niiden lähdekoodi olisi saatavilla.

Tietoturva. Koulutustarkoitukseen käytettävää laajaa, yksityistä ja arkaluontoista dataa säilytetään paikallisesti tai yrityksen palvelimilla, mikä voi altistaa sen tietovuotoriskille tai joutumisen haitallisten toimijoiden käsiin (Coghlan & Quinn, 2024, s. 2341). Eläinlääketieteellisen terveystieteen datan anonymisointi tai tietojen poistaminen koulutuksen päätyttyä ei myöskään suojaa dataa, sillä se voi olla yhdistettävissä muuhun yksilön paljastavaan tietoon, ja malli voi joutua hyökkäyksen kohteeksi tietojen poistamisesta huolimatta (Coghlan & Quinn, 2024, s. 2341). Coghlan ja Quinn (2024, s. 2341) korostavat, että muun muassa tekoälyjen jatkokoulutuksia varten, täytyy varmistaa asiakkaiden tietoisuus riskeistä, sekä pyytää heidän suostumuksensa tietojensa uudelleenkäyttöön.

Luottamus ja epäluottamus. Tekoäly on hyödyllinen eläinlääketieteessä silloin, kun se on luotettava, ja luottamus on perusteltua, mitä ilman tekoälyn käyttö voi johtaa väärinkäyttöön (Coghlan & Quinn, 2024, s. 2341). Coghlan ja Quinn (2024, s. 2341) esittävät, että perusteeton luottamus voi johtaa siihen, ettei tekoälyä käytetä eikä potilas saa sen tuomia hyötyjä, esimerkiksi kiireellisessä patologian analysoinnissa, kun tekoäly voisi nopeuttaa sairastuneen eläimen tutkimusta ja hoitoa. Heidän mukaansa kielteissävytteiset uutiset ja kokemukset voivat kärjistyä epäluottamukseksi koko eläinlääkärikuntaa kohtaan.

Epäluottamusta lisää järjestelmät, jotka ovat läpinäkymättömiä, ja puolestaan liiallinen luottamus voi johtua automaatioharhasta (Coghlan & Quinn, 2024, s. 2341). Coghlan ja Quinn (2024, s. 2341) esittävät, että tekoälypohjainen ennuste saatetaan ajoittain

sivuuuttaa esitystavan ollessa epäselvä tai jos sen antamat ennustukset eivät ole paikkaansa pitäviä. He myös korostavat, että eläinlääkärien tulisi olla tietoisia kliiniseen päätöksentekoon vaikuttavista kaupallisista paineista ja taktiikoista, joita tekoäly-yritykset voivat käyttää markkinoidessaan omia tuotteitaan lääketieteellisen tekoälyn takaamana.

Asiakkaan itsemääräämisoikeus. Coghlanin ja Quinin (2024, s. 2341) mukaan on perusteltua, että eläinlääkärit informoivat asiakkaitaan hoitovaihtoehtojen eduista, haitoista, arvioiduista lopputuloksista, tarvittavien lisätestien tai -hoidon tarpeesta, kustannuksista, sekä hoitomenetelmien vahvuudesta. He huomauttavat, että ihmispotilaiden kohdalla tämä on välttämätöntä, jotta itsemääräämisoikeutta kunnioitettaisiin. Lisäksi he esittävät, että käyttämien tekoälyratkaisujen rajoitukset, luonne, hyödyt, riskit ja mahdollisesti esiintyvät virheet tulisi ymmärtää, ja kertoa niistä asiakkaalle, sillä asiakkaat eivät varmuudella ole tietoisia niistä tai niiden testauksen prosessista ja tuloksista.

Eläinlääkärien tulee myös selittää asiakkaalle diagnoosinsa ja ennusteidensa perusteet ymmärrettävästi. Black box -algoritmien läpinäkymättömyys voi kuitenkin olla esteenä ennusteiden tai suositusten ymmärrettävyydelle, mikä ei kuitenkaan aina häiritse asiakkaita. Perustelut on kuitenkin oltava tarjolla, tai vaihtoehtoisesti tekoälyratkaisuihin täytyy käyttää helpommin ymmärrettävää ja selkeää mallia. (Coghlan & Quinn, 2024, s. 2341).

Tiedon ylikuormitus ja ammattitaidon rapautuminen. Kognitiivisen ajattelun ulkoistaminen voi keventää eläinlääkäreiden työkuormaa ja helpottaa heidän työtään (Appleby & Basran, 2022, s. 822). Coghlan ja Quinn (2024, s. 2342) esittävät, että monimutkainen ja jatkuvasti kehittyvä tekoäly voi myös lisätä tiedon ylikuormittumista, mikä aiheutuu ajan ja motivaation puutteesta opetella uusia teknologioita.

Kuitenkin pitkällä aikavälillä jatkuva koneavusteisuuden käyttö voi osaltaan rappeuttaa eläinlääkärien ammattitaitoa (Coghlan & Quinn, 2024, s. 2342). Coghlanin ja Quinin (2024, s. 2342) mukaan esimerkiksi päätöksenteossa käytettävät nopeat ja kätevät

tukijärjestelmät voivat keventää kognitiivista kuormaa liikaa, minkä seurauksena eläinlääkäriin päätöksentekotaidot, jotka ovat olennaisia eläinlääketieteessä, heikentyvät.

Vastuu tekoälyn ohjaamisesta ja siihen perustuvista lopputuloksista. Termillä vastuukuilu, responsibility gap, tarkoitetaan sitä, miten tekoälyn aiheuttamien haittojen oikeudellisia ja eettisiä vastuutahoja ei ole selkeästi määritelty (Coghlan & Quinn, 2024, s. 2342). Coghlanin ja Quinin (2024, s. 2342) mukaan vastuu on keskeinen käsite etiikassa juuri tästä syystä. He esittävät, että vastuullisia tahoja voivat olla teknologiayritykset, klinikan johto ja omistajat, insinöörit, klinikot, klinikot tai sääntelyviranomaiset.

Coghlan ja Quinn (2024, s. 2342) huomauttavat, että ennen eläinlääketieteellisen tekoälyn saavutettavaa korkeaa luottamuksen tasoa, yksittäinen ammattilainen on edelleen vastuussa eettisesti ja ammatillisesti sen käytöstä. He korostavat, että tämä on merkittävää sisäistä, kun läpinäkymättömiä järjestelmiä, joiden virheet ovat vaikeammin havaittavissa, käytetään eläinlääketieteelliseen arviointiin.

Ympäristövaikutukset. Coghlanin ja Quinin (2024, s. 2342) mukaan, eläinlääketieteellinen tekoäly voi kasvattaa tekoälyn kokonaisvaltaista ympäristöjalanjälkeä. He esittävät, että yleisesti terveydenhuollossa käytettäviä tekoälyjen ympäristövaikutuksia harvoin huomioidaan, vaikka ne olisivat merkittäviä.

Ympäristövaikutusten huomioiminen on toissijaista eläinlääkäriin työssä, sillä huomio on kohdistettuna potilaan hyvinvointiin, tutkimiseen ja hoitamiseen. Eläinlääkärit voivat kuitenkin vaikuttaa tekoälyn ympäristökuormaan suosimalla kestäviä tekoälyratkaisuja mahdollisuuksien tullen. (Coghlan & Quinn, 2024, s. 2342).

6 Johtopäätökset

Tämä kandidaatintutkielma on kuvaileva kirjallisuuskatsaus, jonka tavoitteena oli tarkastella pieneläinten diagnostiikassa, erityisesti diagnostisessa kuvantamisessa ja tautiluokituksessa hyödynnettäviä syväoppimismenetelmiä. Painopisteinä tarkastelussa olivat menetelmien tehokkuus ja tarkkuus. Lisäksi tutkielmassa kartoitettiin, millä tavoin menetelmien käyttöönotto on edistänyt tarkkuuden ja tehokkuuden kehittymistä kliinisessä ympäristössä, sekä tarkasteltiin syväoppimisen soveltamiseen liittyviä keskeisiä mahdollisuuksia ja haasteita eläinlääketieteellisessä kontekstissa.

Syväoppimismalleja on hyödynnetty muun muassa silmä-, sydän- ja maksasairauksien diagnosoinnissa. Neuroverkkopohjaisilla syväoppimismalleilla analysoidut kuvat ovat osoittaneet parempaa tarkkuutta ja tehokkuutta verrattuna perinteisiin arviointimenetelmiin. Analysoidun kirjallisuuden perusteella useat tutkimukset raportoivat parempaa tarkkuutta ja nopeutta perinteisiin menetelmiin verrattuna. Esimerkiksi ihmisen silmälle näkymättömiä piirteitä on pystytty havaitsemaan syväoppimismallien avulla eläinlääketieteellisistä kuvista, mikä on tarkentanut diagnoosia ja hoitoennusteiden arviointia.

Tutkielman kirjallisuuskatsauksen perusteella voidaan todeta konvoluutioneuroverkkojen olevan yleisimmin käytetty diagnostisen kuvantamisen syväoppimismenetelmä. Niiden suorituskyky on ylittänyt merkittävän tarkkuuden esimerkiksi koirien silmä- ja sydänsairauksien luokittelussa. Muun muassa koiran haavaisen sarveiskalvon havaitseminen onnistui konvoluutioneuroverkkomallilla 90 prosentin tarkkuudella. Konvoluutioneuroverkot tarjoavat myös sairauksien aikaisen vaiheen havainnoinnin, mikä parantaa hoitoennusteiden toteutumista. Myös toistuvien neuroverkkojen, kuten RNN ja LSTM, soveltaminen tekstimuotoisiin potilastietoihin, kuten potilaskertomuksiin, antoi lupaavia tuloksia automaattiseen tautikoodien luokitteluun ja ennustamiseen.

Lisäksi tärkeä havainto oli siirto-oppimisen kyky kouluttaa valmiita malleja yhä monimutkaisempien tehtävien ratkaisuun. Siirto-oppiminen oli analysoidun kirjallisuuden mukaan tehokkain työkalu, kun käytettävissä ei ole tarpeeksi dataa. Se soveltaa jo oppimaansa tietoa uusien tehtävien ratkaisemiseksi, mikä tekee siitä erinomaisen työkalun harvinaisten eläintautien, joissa on niukasti dataa tarjolla, luokitteluun ja havainnointiin. Myös puoliöhjattu oppiminen sopii tämän kaltaisiin tehtäviin, koska siinä on saman kaltaisia piirteitä. Lisäksi perinteisiä koneoppimisalgoritmeja, ohjattua, ohjaamatonta ja puoliöhjattua oppimista, käytetään eläinlääketieteessä suurien datamäärien käsittelyssä. Koneoppimisen haaraa, luonnollisen kielen käsittelyä (NLP), voidaan hyödyntää digitaalisten dokumenttien luomisessa eläinlääkärien vapaamuotoisten muistiinpanojen pohjalta.

Syväoppimismenetelmät tarjoavat tehokkaita ja tarkkoja ratkaisuja monipuolisten eläinlääketieteellisten ja teknisten datakokonaisuuksien analysointiin. Menetelmiä voi hyödyntää niin tutkimustyössä kuin käytännön soveltamisessa, sillä ne sopivat moninasiin tehtäviin suorituskykyjensä, ominaisuuksiensa ja mukautuvuutensa ansiosta. Syväoppimismenetelmien hyödyntäminen on yleistynyt viime vuosikymmenen aikana, kun niiden ominaisuuksia on alettu tutkima ja soveltaa tarkemmin. Syväoppimismenetelmien soveltamisen haasteena on datan vähäinen määrä ja sen vaihtelu, mikä on hankaloittanut mallien kouluttamisprosessia. Menetelmien soveltamisen mahdollisuuksia tarjoaa mallien siirrettävyys, jatkokoulutusmahdollisuudet, sekä tekstidatan ja kuvantamisen yhdistäminen diagnostiikassa.

Tämän tutkielman johtopäätöksenä voidaan todeta, että syväoppimismallit kykenevät tehokkaasti ja tarkasti toimimaan eläinlääkäreiden työkaluna diagnosoimisessa. Menetelmien avulla voidaan parantaa hoitopäätösten luotettavuutta, nopeuttaa diagnosointiprosessia ja tarjota helpotusta resurssien vähäisyyteen. Tämä kirjallisuuskatsaus myös täydentää eläinlääketieteellistä kirjallisuutta alueella, jossa syvällisiä analyysejä ja kartoituksia on niukasti. Koska tutkielma on kirjallisuuskatsaus, löydökset perustuvat muiden tutkijoiden tuottamiin aineistoihin ja arviointeihin. Vertaisarvioitujen tutkimusten välillä oli joitakin eroja, esimerkiksi datan laadussa ja

sovelluskonteksteissa. Datan saatavuus ja menetelmien avoimuus oli vaihtelevaa, mikä voi heikentää tulosten toistettavuutta.

Tulevaisuudessa empiiristen tutkimusten, joissa verrataan eri syväoppimismalleja, toteuttaminen olisi hyödyllistä. Myös tekstidatan ja kuvantamisen yhdistäminen voisi tarjota tehokkaamman ja tarkemman järjestelmän, joka tarjoaisi paremman suorituskyvyn diagnoosien tuottamiseksi. Eläinklinikoille tarjottavien konkreettisten syväoppimissovellusten toteuttamiseksi tarvitaan tutkimusta siitä, miten menetelmiä voitaisiin integroida kliiniseen eläinlääkärityöhön. Koska tekoälyyn liittyy paljon riskejä, syväoppimismallien käyttöönotto vaatii tarkkaa testausta ja seurantaa, jotta riskit voidaan minimoida.

Eläinlääketieteellisen tekoälyn eettisiä ja oikeudellisia näkökulmia ei ole selkeästi määritetty. Tämä voi edesauttaa epävarmuutta ja epäluottamusta tekoälyn käytössä eläinlääketieteellisessä diagnosoinnissa, sekä ennakkoluuloja uusia teknologioita kohtaan. Vielä tällä hetkellä eläinlääkärit ovat itse vastuussa tekoälyyn liittyvissä dilemmissa. Eläinlääketieteessä tekoälyyn liittyvät haasteet voivat olla hankalampia, koska eläinten oikeudet eivät ole verrattavissa ihmisten oikeuksiin. Tekoälyllä arvioidut diagnoosit ja hoitoennusteet tulee olla mahdollista perustella ja selittää, mikä voi riippuen mallin laajuudesta olla haastavaa. Tekoälyn käyttö diagnoosien määrittämisen avustamisessa itsessään täytyy olla perusteltua, kuin myös tekoälyn käyttämättä jättäminen, jos se olisi saatavilla. Näiden syiden takia, tekoälyn käyttöönotto vaatii erityiskoulutusta, jotta sitä käyttävät eläinlääkärit olisivat tietoisia sen monikerroksisista ominaisuuksista, riskeistä sekä hyödyistä. Kustannussyistä voi kuitenkin olla haastavaa ottaa tekoälyratkaisuja käyttöön esimerkiksi pienemmillä klinikoilla.

Syväoppimismallien kehittäminen ja testaaminen on eläinlääketieteessä helpompaa oikeudellisesta näkökulmasta, koska eläinten sairaustiedot eivät ole yhtä salattuja kuin ihmisten. Tästä huolimatta lemmikkieläinten omistajilta on pyydettävä suostumus eläimen tietojen luovuttamiseen tutkimustarkoituksiin. Vaikka eläinten sairaustietojen käytettävyys on helpompaa ihmisiin verrattuna, syväoppimismallien kehitystä hidastaa vähäinen datan määrä. Tietyillä syvä- ja koneoppimismalleilla, kuten siirto-oppimisella

tai puoliohjatulla oppimisella, voidaan kuitenkin päästä hyviin tuloksiin datan niukkuudesta huolimatta.

Tutkielman toteutus on ollut palkitseva prosessi, se on vaatinut perehtymistä niin tekoälyn, syväoppimisen ja koneoppimisen, kuin eläinlääketieteellisen diagnostiikan kysymyksiin. Koska vastaavaa aihetta käsittelevää analyysiä ei löytynyt, tutkielma rakentaa uutta näkökulmaa valikoituihin tieteellisiin lähteisiin ja käytännön esimerkkeihin pohjautuen.

Lähteet

- Antoniadis, P. (2025, 13. helmikuuta). *Neural Networks: Difference Between Conv and FC Layers*. Baeldung. Noudettu 24. helmikuuta 2025 osoitteesta <https://www.baeldung.com/cs/neural-networks-conv-fc-layers>
- Appleby, R. B. & Basran, P. S. (2022, 30. maaliskuuta). Artificial intelligence in veterinary medicine. *AVMA Publications*, 260, 8. <https://doi.org/10.2460/javma.22.03.0093>
- Banzato, T., Bonsembiante, F., Aresu, L., Gelain, M. E., Burti, S. & Zotti, A. (2018, maaliskuu). Use of transfer learning to detect diffuse degenerative hepatic diseases from ultrasound images in dogs: A methodological study. *The Veterinary Journal*, 233, 35–40. <https://doi.org/10.1016/j.tvjl.2017.12.026>
- Basran, P. S. & Appleby, R. B. (2022). The unmet potential of artificial intelligence in veterinary medicine. *American Journal of Veterinary Research*, 83 (3), 385–392. <https://doi.org/10.2460/ajvr.22.03.0038>
- Biourge, V., Delmotte, S., Feugier, A., Bradley, R., McAllister, M. & Elliott, J. (2020, 18. elokuuta). An artificial neural network-based model to predict chronic kidney disease in aged cats. *Journal of Veterinary Internal Medicine*, 34, 1920–1931. [10.1111/jvim.15892](https://doi.org/10.1111/jvim.15892)
- Burti, S., Longhin Osti, V., Zotti, A. & Banzato, T. (2020, elokuu). Use of deep learning to detect cardiomegaly on thoracic radiographs in dogs. *The Veterinary Journal*, 262, 1055505. <https://doi.org/10.1016/j.tvjl.2020.105505>
- Caputa, J., Wielgosz, M., Łukasik, D., Russek, P., Grzeszczyk, J., Karwatowski, M., Mazurek, S., Frączek, R., Śmiech, A., Jamro, E., Koryciak, S., Dąbrowska-Brouch, A., Pietroń, M. & Wiatr, K. (2024, 28. helmikuuta). Using Super-Resolution for Enhancing Visual Perception and Segmentation Performance in Veterinary

Cytology. *Life*, 14, 3. <https://doi.org/10.3390/life14030321>

Coghlan, S. & Quinn, T. (2023, 10. toukokuuta). Ethics of using artificial intelligence (AI) in veterinary medicine. *AI & Soc*, 39, 2337–2348.

<https://doi.org/10.1007/s00146-023-01686-1>

Dubey, R., B. & Hanmandlu, M. (2012, 17.–19. joulukuuta). Integration of CAD into PACS. *IEEE Xplore*, 1–6. 10.1109/ICPCES.2012.6508034.

Dumortier, L., Guépin, F., Delignette-Muller, M., Boulocher, C. & Grenier, T. (2022, 6. heinäkuuta). Deep learning in veterinary medicine, an approach based on CNN to detect pulmonary abnormalities from lateral thoracic radiographs in cats.

Scientific Reports, 12, 11418. <https://doi.org/10.1038/s41598-022-14993-2>

Groendahl, A. R., Huynh, B. N., Tomic, O., Sjøvik, Å., Dale, E., Malinen, E., Skogmo, H. K. & Futsaether, C. M. (2023, 21. maaliskuuta). Automatic gross tumor segmentation of canine head and neck cancer using deep learning and cross-species transfer learning. *Frontiers in Veterinary Science*, 10.

<https://doi.org/10.3389/fvets.2023.1143986>

Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S. & Lew, M. S. (2015, 26. marraskuuta) Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48.

<http://dx.doi.org/10.1016/j.neucom.2015.09.116>

Hennessey, E., DiFazio, M., Hennessey, R. & Cassel, N. (2022, 7. heinäkuuta). Artificial intelligence in veterinary diagnostic imaging: A literature review. *Wiley Online Library: Vet Radiol Ultrasound*, 63, 1: 851–870.

<https://doi/epdf/10.1111/vru.13163>

Hosna, A., Merry, E., Gyalmo, J., Alom, Z., Aung, Z. & Azim, M. A. (2022, 22. lokakuuta). Transfer learning: a friendly introduction. *Journal of Big Data*, 9, 102.

<https://doi.org/10.1186/s40537-022-00652-w>

Jobin, A., Ienca, M. & Vayena, E. (2019, 2. syyskuuta). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1, 389–399. <https://doi.org/10.1038/s42256-019-0088-2>

Kangasniemi, M., Utriainen, K., Ahonen, S., Pietilä, A., Jääskeläinen, P. & Liikanen, E. (2013, 1. huhtikuuta). *Kuvaileva kirjallisuuskatsaus: eteneminen tutkimuskysymyksestä jäsenettyyn tietoon*. *Hoitotiede*. Noudettu 22. huhtikuuta 2025 osoitteesta <https://journal.fi/hoitotiede/article/view/128286>

Kathrani, A., Terwin, I., Ancheta, K., Psifidi, A., Le Calvez, S. & Williams, J. (2024, 14. maaliskuuta). A Preliminary Study Assessing a Transfer Learning Approach to Intestinal Image Analysis to Help Determine Treatment Response in Canine Protein-Losing Enteropathy. *Veterinary Sciences*, 11, 3. <https://doi.org/10.3390/vetsci11030129>

Kim, J. Y., Lee, H. E., Choi, Y. H., Lee, S. J. & Jeon, J. S. (2019, 2. lokakuuta). CNN-based diagnosis models for canine ulcerative keratitis. *Nature research : Scientific Reports*, 9, 14209. <https://doi.org/10.1038/s41598-019-50437-0>

Kolari, J. & Kallio, A. (2023, 23. maaliskuuta). *Tekoäly 123: Matkaopas tulevaisuuteen*. Docendo.

Kucukkara, Z., Ozkan, I. A., Tasdemir, S. & Ceylan, O. (2025, helmikuu). Classification of chicken Eimeria species through deep transfer learning models : A comparative study on model efficacy. *Veterinary Parasitology*, 334, 110400. <https://doi.org/10.1016/j.vetpar.2025.110400>

Lee, J., Jun, S., Cho, Y., Lee, H., Kim, G. B., Seo, J. B. & Kim, N. (2017, 29. maaliskuuta). Deep Learning in Medical Imaging: General Overview. *Korean Journal of Radiology*, 18 (4), 570–584. <https://doi.org/10.3348/kjr.2017.18.4.570>

Lopez Pineda, A., Bear Don't Walk IV, O. J., Venkataraman, G. R., Zehnder, A. M.,

Ayyar, S., Page, R. L., Bustamante, C. D. & Rivas, M. A. (2019, 16. helmikuuta). Deep learning facilitates rapid classification of human and veterinary clinical narratives. *bioRxiv : The Preprint Server For Biology*.
<https://doi.org/10.1101/429720>

Nelson, D. (2020, 23. elokuuta). *Mitä ovat RNN:t ja LSTM:t syväoppimisessa?* Unite.AI. Haettu 24. helmikuuta 2025 osoitteesta
<https://www.unite.ai/fi/what-are-rnns-and-lstms-in-deep-learning/>

Nie, A., Zehnder, A., Page, R. L., Zhang, Y., Lopez Pineda, A., Rivas, M. A., Bustamante, C. D. & Zou, J. (2018, 24. lokakuuta). DeepTag: inferring diagnoses from veterinary clinical notes. *npj Digital Med*, 1, 60.
<https://doi.org/10.1038/s41746-018-0067-8>

Odo, A., Muns, R., Boyle, L. & Kyriazakis, I. (2023, 20. kesäkuuta). Video Analysis Using Deep Learning for Automated Quantification of Ear Biting in Pigs. *IEEEAccess*, 11, 59744–59757. 10.1109/ACCESS.2023.3285144

Oppermann, A. (2023). *[Syväverkkokaavio]*. Built In. Saatavilla:
<https://builtin.com/machine-learning/deep-learning>

Pereira, A. I., Franco-Gonçalo, P., Leite, P., Ribeiro, A., Alves-Pimenta, M. S., Colaço, B., Loureiro, C., Gonçalves, L., Filipe, V. & Ginja, M. (2023, 28. huhtikuuta). Artificial Intelligence in Veterinary Imaging: An overview. *Veterinary Sciences*, 10(5), 320.
<https://doi.org/10.3390/vetsci10050320>

Pesapane, F., Codari, M. & Sardanelli, F. (2018, 24. lokakuuta). Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European Radiology Experimental*, 2, 35.
<https://doi.org/10.1186/s41747-018-0061-6>

SAP. (n.d.). *What Is Machine Learning?* Noudettu 22. helmikuuta 2025 osoitteesta
<https://www.sap.com/finland/products/artificial-intelligence/what-is-machine-learning.html>

Shiri, F., M., Perumal, T., Mustapha, N. & Mohamed, R. (2024, 20. marraskuuta). A Comprehensive Overview and Comparative Analysis on Deep Learning Models. *Journal on Artificial Intelligence*, 6, 301–360.
<https://doi.org/10.32604/jai.2024.054314>

Unzueta, D. & Whitfield, B. (2025, 24. helmikuuta). Fully Connected Layer vs. Convolutional Layer: Explained. *Builtin*. Haettu 11. maaliskuuta 2025 osoitteesta
<https://builtin.com/machine-learning/fully-connected-layer>

Zhang, Y., Nie, A., Zehnder, A., Page, R. L. & Zou, J. (2019, 8. toukokuuta). VetTag: improving automated veterinary diagnosis coding via large-scale language modeling. *njp Digital Medicine*, 2, 35. <https://doi.org/10.1038/s41746-019-0113-1>