

Saska Patronen

Koneoppiminen radiologiassa

Tietotekniikan kandidaatintutkielma

28. helmikuuta 2024

Jyväskylän yliopisto

Informaatioteknologian tiedekunta

Tekijä: Saska Patronen

Yhteystiedot: saska.v.patronen@student.jyu.fi

Ohjaaja: Tuomo Rossi

Työn nimi: Koneoppiminen radiologiassa

Title in English: Machine learning in radiology

Työ: Kandidaatintutkielma

Sivumäärä: 19+0

Tiivistelmä: Koneoppiminen on kehittynyt viime aikoina nopeaa vauhtia ja sitä on sovellettu monilla eri aloilla. Tässä kirjallisuuskatsauksessa käsitellään koneoppimisen soveltamista radiologian kuvantamisessa ja siihen liittyviä haasteita. Tutkielmassa käytiin läpi kolmea sovelluskohdetta kuvantamisessa sekä havaittiin koneoppimiseen liittyviä haasteita radiologiassa. Haasteille kuitenkin löytyi ehdotettuja ratkaisuja.

Avainsanat: Koneoppiminen, radiologia, neuroverkko, syväoppiminen

Abstract: Machine learning has developed rapidly in recent times and has been applied in a wide range of fields. This literature review discusses the application of machine learning in radiology imaging and the challenges involved. The thesis reviewed three applications in imaging and identified challenges related to machine learning in radiology. However, proposed solutions to these challenges were found.

Keywords: Machine learning, radiology, neural network, deep learning

Kuviot

Kuvio 1. Kuvio 1	3
Kuvio 2. Kuvio 2	9

Sisällys

1	JOHDANTO	1
2	KONEOPPIMINEN	2
2.1	Koneoppimisen tyypit	2
2.2	Neuroverkot	2
2.3	Syväoppiminen ja konvoluutioverkot	3
2.4	Siirrosoppiminen	4
3	KONEOPPIMISEN SOVELTAMINEN KUVANTAMISESSA	5
3.1	Lääketieteellisten kuvien luokittelu	5
3.2	Lääketieteellisen kuvan segmentointi	6
3.3	Kuvien rekisteröinti	6
4	DATAN JA KONEOPPIMISEN HAASTEET RADIOLOGIASSA	8
4.1	Data	8
4.2	Yli- ja alisovitus	8
4.3	Algoritmien yleistettävyys	9
4.4	Läpinäkyvyys	10
5	YHTEENVETO	12
	LÄHTEET	13

1 Johdanto

Radiologia on lääketieteen erikoisala, joka keskittyy kuvantamaan kehon sisäisiä rakenteita ja toimintoja erilaisilla kuvantamismenetelmillä. Radiologian alalla koneoppiminen on viime aikoina saavuttanut merkittävää huomiota ja sen käyttö kliinisessä käytössä on tullut yhä yleisemmäksi. Koneoppiminen mahdollistaa suurien kuvamäärien analysoinnin ja piilevien tietojen löytämisen, joihin perinteiset menetelmät ovat kykenemättömiä tai liian hitaita. Tämä voi auttaa radiologeja diagnosoimaan sairauksia aiemmin ja tarkemmin, mikä parantaa potilaiden hoitoa sekä helpottaa radiologien työkuormaa.

Lakhani ym. 2018 toteavat, että koneoppimisen viimeaikaisen kehityksen voidaan katsoa johtuvan kolmesta eri tekijästä:

1. Suurten datakokonaisuuksien saatavuus
2. Nykyaikaisten grafiikkaprosessoreiden mahdollistava rinnakkainen laskentateho.
3. Kehittyneet algoritmit.

Tämän tutkielman tavoitteena on tutkia miten koneoppimista voidaan soveltaa radiologisessa kuvantamisessa sekä pohtia minkälaisia haasteita koneoppiminen käyttö radiologiassa pitää sisällään. Tutkielma on toteutettu kirjalliskatsauksena. Katsauksen lähteet on haettu Google Scholar palvelun avulla. Lähteiden valinnassa on kiinnitetty huomiota niiden julkaisualueeseen sekä julkaisu ajankohtaan.

Tutkielma koostuu viidestä luvusta. Luvussa 2 tutustutaan koneoppimisen peruskäsitteisiin, jotka ovat tärkeitä tämän tutkielman kannalta. Luvussa 3 esitellään kolme sovelluskohdetta koneoppimiselle radiologisessa kuvantamisessa. Luvussa 4 käydään läpi erilaisia ongelmakohtia koneoppimisen soveltamisessa radiologiassa sekä pohditaan mahdollisia ratkaisuja. Viimeisessä luvussa 5 muodostetaan yhteenveto.

2 Koneoppiminen

Koneoppiminen on tekoälyn ja tietojenkäsittelytieteen haara, jossa pyritään dataa ja algoritmeja käyttäen imitoimaan ihmisten tyyliä oppia (“IBM, What is machine learning?” 2023). Koneoppiminen mahdollistaa sellaisten algoritmien luomisen, jotka voivat oppia ja tehdä ennusteita. Koneoppimisen viimeaikaista edistystä on vauhdittanut sekä uusien oppimisalgoritmien ja teorian kehittyminen että verkkodatan ja edullisten laskentamenetelmien räjähdysmäinen lisääntyminen (Jordan ja Mitchell 2015).

2.1 Koneoppimisen tyypit

Koneoppimistehtävät luokitellaan tyypillisesti seuraavasti kolmeen laajaan kategoriaan tehtävän tyypin mukaan: ohjattu oppiminen, ohjaamaton oppiminen ja vahvistusoppiminen (Choy ym. 2018).

Ohjatussa oppimisessa algoritmille syötetään opetusvaiheessa dataa, jolle on jo annettu oikea luokitus (Sathya, Abraham ym. 2013). Ihmisasiantuntijat merkitsevät yleensä odotetut tulokset, ja ne toimivat perustotuutena (ground truth) algoritmille. Koneoppimisessa perustotuudella tarkoitetaan todeksi oletettua tietoa (Choy ym. 2018). Ohjaamattomassa oppimisessä algoritmille ei syötetä valmiiksi merkittyä dataa, koneoppimistehtävän tarkoituksena on löytää rakenne datassa ja erotella se klustereihin tai ryhmiin (Choy ym. 2018).

Vahvistusoppimisellä tarkoitetaan koneoppimisen menetelmää, jossa oppimisalgoritmi eli agentti on vuorovaikutuksessa ympäristön kanssa, ja vastaan ottaa ympäristöltä negatiivista tai positiivista palautetta. Agentin tavoitteena on oppia toimintatapa, joka maksimoi kumulatiivisen palkkion ajan kuluessa (Wiering ja Van Otterlo 2012).

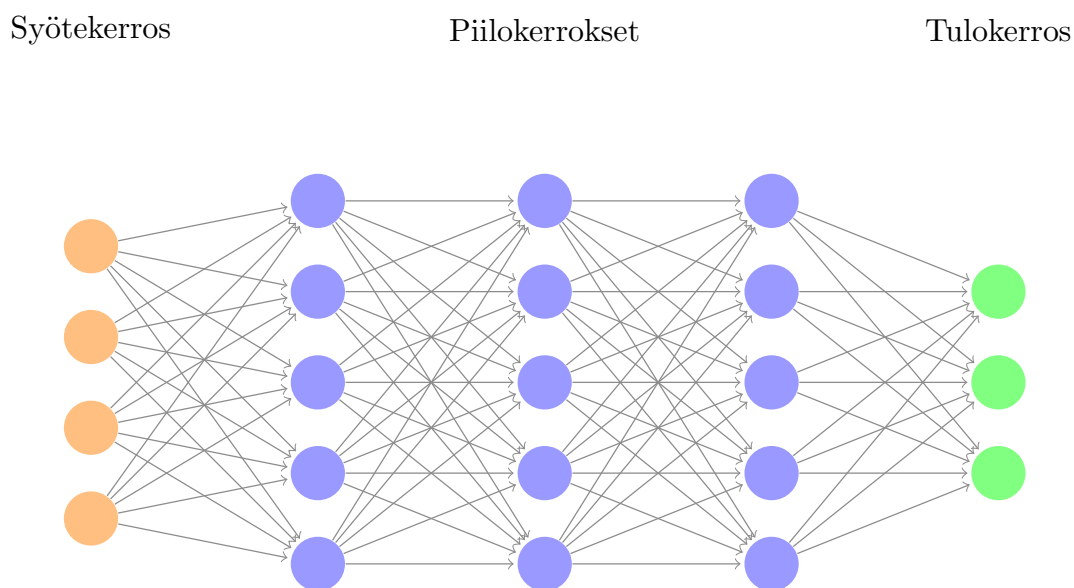
2.2 Neuroverkot

Keinotekoiset neuroverkot ovat tilastollisia ja matemaattisia menetelmiä, jotka ovat osa koneoppimista. Nämä mallit on kehitetty biologisen keskushermosto rakenteita jäljitellen. Keinotekoiset neuroverkot koostuvat kerroksista neuroneita. Rakenteellisesti neuroverkot si-

sältävät yhden syötekerroksen, yhden tai useamman piilokerroksen ja yhden tuloskerroksen. Jokainen piilokerros koostuu neuroneista, jotka ovat kytketty kaikkiin edellisen kerroksen neuroneihin. Opetusvaiheessa, joka voidaan toteuttaa ohjatusti tai ohjaamattomasti, neuronien välille saadaan kytkentäkohtainen paino, joiden perusteella malli antaa tulon (Choy ym. 2018).

2.3 Syväoppiminen ja konvoluutioverkot

Syväoppiminen on osa koneoppimista, jossa käytetään useamman kerroksen neuroverkkoja (Kuvio 1). Viime vuosina syväoppimisella on saatu hyviä tuloksia erilaisissa tehtävissä, esimerkiksi visuaalisessa tunistamisessa ja luonnollisen kielen käsittelyssä. Syväoppimisneuroverkkojen joukosta eniten on tutkittu konvoluutioneuroverkkoja (Convolutional Neural Network, CNN), (Gu ym. 2018) ne ovat myös tällä hetkellä yleisimmin käytetty koneoppimistekniikka lääketieteellisessä kuvantamisessa (Choy ym. 2018).



Kuvio 1. Syvä neuroverkko jossa kolme piilokerrosta. (Li ym. 2021)

Konvoluutioneuroverkkojen piilokerrokset koostuvat yleisesti konvoluutiakerroksista (convolutional layer), koontikerroksista (pooling layer), yhdistelmäkerroksista (fully connected layer) ja normalisointikerroksista (normalization layers) (Choy ym. 2018). Konvoluutiokerros on tärkeä osa konvoluutioneuroverkkoja, sen tehtävä on louhia ominaisuuksia. Kuvan

tunnistuksessa se käyttää konvoluutio-operaattoreita syötekuvan konvoluutioon ja tallentaa konvoluutiotulokset konvoluutiokerroksen eri kanaviin (Li, Zhai ja Sun 2022). Koontikerroksen tehtävänä on vähentää esityksen dimensioita (spatial dimension) laskentasuorituskyvyn parantamiseksi ja myös vähentämään ylisovittamisen (overfitting) mahdollisuutta (Choy ym. 2018).

2.4 Siirrosoppiminen

Siirrosoppiminen (Transfer learning) on koneoppimisessa yleisesti käytetty menetelmä, jonka tarkoituksena on parantaa oppimista tietyllä kohdealueella (target domain) kouluttamalla malleja, muilla eri lähdealueilla (source domain) sijaitsevilla data joukoilla, joilla on samankaltaisia piirteitä (L'Heureux ym. 2017).

3 Koneoppimisen soveltaminen kuvantamisessa

Radiologian jokapäiväisessä käytännössä radiologit lukevat ja tulkitsevat eri menetelmillä otettuja lääketieteellisiä kuvia. Yleisimmät menetelmät joilla kuvia otetaan ovat röntgenkuvaus, tietokonetomografia (TT), ultraääni, magneettikuvaus (MRI) ja positroniemissiotomografia (PET). Nykyaikaisen lääketieteellisen teknologian kehittyessä kuvantamistietojen määrä kasvaa nopeasti. Esimerkiksi TT-tutkimuksissa käytetään aiempaa ohuempia viipaleita, jolloin radiologien työkuorma lisääntyy. Koneoppiminen mahdollistaa lääketieteellisten kuvien automaattisen analysoinnin ja diagnoosin. Se voi mahdollisesti vähentää radiologien työmäärää (Wang ja Summers 2012).

Tässä luvussa käsitellään kolmea eri koneoppimisen sovellusta lääketieteellisessä kuvantamisessa.

3.1 Lääketieteellisten kuvien luokittelu

Lääketieteellisten kuvien luokittelulla (Medical image classification) tarkoitetaan lääketieteellisen kuva-analyysin vaihetta, jossa luokitellaan lääketieteellisiä kuvia eri luokkiin kuvan tyypin tai joidenkin rakenteiden tai sairauksien ilmentymien mukaan. Tavoitteena on suorittaa algoritmien avulla lääketieteellisten kuvien alustava analyysi, jossa saadaan kuvasta ymmäryks ja voidaan tunnistaa tehokkaasti vaurioalueet, mikä auttaa lääkäreitä sairauksien diagnoosissa (An, Li ja Ma 2021).

Yadav ja Jadhav 2019 kirjoittavat julkaisussaan kuinka perinteisiä koneoppimismenetelmiä, kuten tukivektorimenelmiä, on käytetty lääketieteellisten kuvien luokittelussa jo pitkän aikaa. Yadav ja Jadhav ottavat esiin näissä menetelmissä olevan ongelmia, kuten niiden tehokkuus, sekä niiden kehityksen hidastuminen viime vuosina. Heidän mukaan CNN-pohjaiset menetelmät ovat perinteisiä menetelmiä parempia, koska ne pystyvät oppimaan ja valitsemaan ominaisuudet automaattisesti ja tehokkaasti.

3.2 Lääketieteellisen kuvan segmentointi

Segmentointi on tärkeä vaihe kuva-analyysissä. Segmentointi on prosessi, jossa kuva jaetaan alueisiin. Alueilla on samankaltaisia ominaisuuksia, kuten harmaasävy, väri, rakenne, kirkkaus, kontrasti jne. Kuvien segmentointiin käytettävissä olevat tekniikat voidaan jakaa karkeasti kahteen luokkaan, harmaasävyjen perusteella segmentointi ja tekstuurin perusteella segmentointi. (Sharma ym. 2008) Lääketieteellisen kuvan segmennoinin tavoite on leesioiden, elimien ja muiden rakenteiden pikseleiden tai vokseleiden tunnistaminen tausta-alueista (Chen ym. 2022). Chen ym. 2022 mukaan kaikista yleisimmistä kuva-analyysitehtävistä, segmentointi vaatii eniten ohjausta, eli suurimman määrän hyvin merkittyä opetusdataa. (Chen ym. 2022).

Weston ym. 2019 vertasivat U-Net arkkitehtuuriin perustuvan konvoluutioverkon segmentointi kykyä asiantuntijoiden manuaaliseen segmentointiin. Tutkimuksessa pyrittiin toteuttamaan vatsan TT-kuvien automaattinen segmentointi kehonkoostumuksen määrittämiseen. Malli koulutusjoukkona käytettiin 2430 kaksiulotteista TT-tutkimusta ja sen suoriutumista testattiin 270:n TT-tutkimuksen aineistolla. Sitä testattiin lisäksi erillisellä aineistolla, joka koostui 2369 potilaasta, joilla oli hepatosellulaarinen karsinooma. Mallin suorituskyky vastasi tai ylitti TT-tutkimusten asiantuntijoiden suorittaman manuaalisen segmentoinnin tarkkuuden sekä testiaineiston että hepatosellulaarista karsinoomaa koskevan aineiston osalta.

3.3 Kuvien rekisteröinti

Chen ym. (2022) mukaan rekisteröinti, joka tarkoittaa kahden tai useamman kuvan kohdistamista yhteen koordinaatistoon niin, että niiden sisällöt vastaavat toisiaan, on tärkeä vaihe monissa lääketieteellisissä kuvantamistehtävissä. Kuvarekisteröinti voidaan jakaa kahteen ryhmään: jäykät (rigid) ja muotoutuvat (deformable). Jäykässä rekisteröinnissä kaikki kuvapikselit kokevat yhtenäisesti yksinkertaisen muunnoksen, kun taas muotoutuva rekisteröinti pyrkii luomaan epäyhtenäisen kartoituksen kuvien välille. Viime vuosina syväoppimissovellusten määrä tähän tutkimusaiheeseen liittyen on kasvanut.

Balakrishnan ym. 2019 tutkimuksessa esitetään oppimiseen perustuva kehys VoxelMorph, joka käyttää konvoluutioneuroverkkoa parametrisoimaan funktion, joka kohdistaa syötteen

kuvaparin muunnoskentän avulla. Tutkimus toteutettiin tutkimalla aivojen MRI-kuvia, mutta tutkijoiden mukaan se ei ole rajoittunut tiettyyn kuvatyyppiin tai anatomiaan. Tutkimuksessa tutkittiin kahta erilaista koulutusstrategiaa: ohjaamatonta ja ohjattua hyödyntäen segmentoinnin aputietoja. Tutkijat totesivat ohjaamattoman mallin tarkkuuden olevan verrattavissa huippuluokan menetelmiin toimien kuitenkin moninkertaisesti nopeammin. Mallilla onnistuttiin lyhentämään laskenta-aika tunneista minuutteihin kun käytössä oli suoritin ja alle sekuntiin GPU:ta käyttäessä. Ohjattu malli paransi rekisteröintitarkkuutta.

4 Datan ja koneoppimisen haasteet radiologiassa

Tässä luvussa käsitellään dataan ja koneoppimiseen liittyviä haasteita lääketieteellisessä kuvantamisessa. Koneoppimisessa data on keskeisessä roolissa, sillä algoritmit oppivat datan pohjalta. Koneoppimisessa tarvitaan riittävä määrä laadukasta dataa, joka kattaa mahdollisimman hyvin käsiteltävän ilmiön. Laadukas data on luotettavaa ja edustavaa, eli sen tulee olla mahdollisimman lähellä todellisuutta.

4.1 Data

Zhang ja Sejdić 2019 kertovat lääketieteessä sovellettavat algoritmit riippuvat kahdesta tärkeästä tekijästä: saavutetusta tarkkuudesta sekä kyvystä käsitellä suuria tietomääriä, erityisesti suuren aineiston käsittelyn luotettavuudesta (robustness). Heidän mukaan useissa koneoppimiseen liittyvissä tutkimuksissa valitun aineiston koko on suhteellisen pieni. Tämä johtuu potilaiden rajallisesta potilaiden saatavuudesta tai rajoitetusta diagnostisesta työstä tutkimusasetelmassa.

Chen ym. 2022 kirjoittavat että, radiologisen kuva-analyysin suorituskyvyn kehityksen parantamista vaikeuttaa vaatimus suurista merkityiden datakokonaisuuksien määristä. He ehdottavat ongelmaa helpottavaksi ratkaisuksi siirrosoppimista.

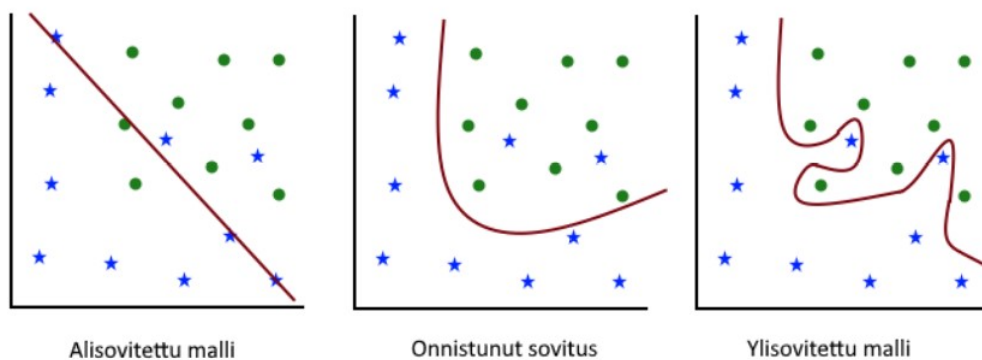
4.2 Yli- ja alisovitus

Ylisovittamisella (Kuvio 2) tarkoitetaan tilannetta, jossa koulutettu malli toimii erittäin hyvin koulutusdatalla, mutta epäonnistuu oppimisen aikana näkemättömällä datalla. Ylisovittaminen tapahtuu, kun mallin suorituskyky jatkaa paranemista koulutusdatassa, mutta heikkenee validointidatassa. Kun koulutusdata on epätasapainossa tai otoskoko ei ole tarpeeksi suuri, algoritmi saattaa virheellisesti tunnistaa ominaisuuksien välisen suhteen merkittäväksi ennusteen kannalta. Tämä suhde saattaa johtua sattumasta eikä välttämättä päde käytettäessä suurempaa tai edustavampaa datajoukkoa (Willeminck ym. 2020).

Eche ym. 2021 toteavat julkaisussaan lääketieteellisen kuvantamisen kirjallisuudessa esiinty-

vän usein ylisovittamista. Ensimmäiseksi syyksi tälle he pitävät lääketieteellisen datan epätasapainoisuutta, koska jotkin sairaudet ovat yleisempiä kuin toiset. Mitä harvinaisempi sairaus on, sitä pienempi on sen esiintymistiheys harjoitusjoukossa. Toisena syynä on se, että mallien kehityksen aikana käytetään usein suurta määrää potentiaalisia ominaisuuksia, jotta tärkeä tieto ei katoa ja potilaiden hoitoa voidaan parantaa.

Yksi keino välttää ylisovittamista on yksinkertaistaa mallia vähentämällä käytettyjen ominaisuuksien määrää, jotta opetusaineistosta opittaisiin vain olennaiset kaavat ja vältettäisiin turhien kuvioitten oppiminen. Tätä kutsutaan ulottuvuuden vähentämiseksi. Yksinkertaistaminen voi kuitenkin johtaa alisovittamiseen, jos malli ei huomaa tärkeitä yhteyksiä (Eche ym. 2021). Alisovittaminen (Kuvio 2) on tilanne, jossa koulutettu malli epäonnistuu koulutusdatalla sekä oppimisen aikana näkemättömällä datalla.



Kuvio 2. Kuva ali-, yli ja onnistuneesta sovituksesta.

(Moore ym. 2019)

4.3 Algoritmien yleistettävyys

Yleistettävyys viittaa koneoppimismallin kykyyn luokittelemaan tai ennustamaan aiemmin näkemätöntä dataa (*What is Generalization in Machine Learning?* 2022). Se on tärkeä osa koneoppimista, koska se määrittää kuinka hyvin malli toimii uusilla tiedoilla. Malli, joka yleistyy hyvin, pystyy tekemään tarkkoja ennusteita uudesta datasta, kun taas malli, joka ei yleisty hyvin, saattaa ylisovittaa koulutusdatan ja suoriutua huonosti uudella datalla.

Willemink ym. 2020 kirjoittavat kuinka suhteellisen pienet, noin satojen tapausten, aineistot voivat olla riittäviä tiettyjä kohdennettuja sovelluksia tai väestöryhmiä varten. Mutta yleistettävyyden kannalta laajat aineistot ovat yleensä tarpeellisia. Suuria otoskokoja tarvitaan etenkin heterogeenisten väestöjen kohdalla, koska esimerkiksi algoritmin kouluttaminen eurooppalaisilla laitoksilla otetuilla kuvilla ja sen käyttäminen aasialaisessa väestössä voi johdattaa väestö- tai taudin esiintyvyysharhaan, mikä voi vaikuttaa algoritmin suorituskykyyn. Tietokonenäkötehtävien (computer vision tasks) algoritmien suorituskyky kasvaa logaritmisesti harjoitusdatan määrän kasvaessa, tämän vuoksi asian mukainen otoskoko on tarpeellinen.

Yhtenä mahdollisena ratkaisuna Willemink ym. 2020 esittävät osittain ohjatun oppimisen käyttämisen täysin ohjatun sijaan. Koska tällöin ei tarvittaisi niin suurta määrää kommentoituja kuvia mallin opettamiseen. Toinen heidän esittämä ratkaisu on generatiivisten vastakkaisverkkojen (Generative adversarial networks, GAN) avulla tuotetun synteettisen datan lisääminen harjoitusdatajoukkoihin havaitsemis- ja luokittelualgoritmien kehittämistä varten. (Willemink ym. 2020) Frid-Adar ym. 2018 tutkimuksessa käytettiin GAN-tekniikkaa kasvattamaan datan määrää ja heterogeenisyyttä koulutusjoukossa. Tutkimuksessa oli käytössä tietokanta, joka sisälsi 182 CT-kuvaa maksavaurioista. Perinteisiin datan lisäämiskeinoihin verrattuna, GAN-tekniikan avulla parannetulla koulutusjoukolla malli saavutti 7 % paremmat tulokset luokittelutehtävässä.

4.4 Läpinäkyvyys

Koneoppiminen luontaisesti tuottaa monimutkaisia funktioita, joiden avulla saatujen lopputulosten logiikka on vaikea selvittää. Koneoppimisalgoritmit yleensä antavat tuloksen sille annetun syötteen perusteella, ilman sisäisen logiikan läpinäkyvyyttä, tätä ilmiötä kutsutaan mustaksi laatikoksi (black box).

Brady ja Neri 2020 kertovat tekoälyn ja koneoppimisen menestyksen kannalta on tärkeää, että potilaat voivat luottaa työkalujen päätöksentekoon. Tällöin olisi tärkeää ymmärtää miten tekoäly on päätenyt johonkin lopputulokseen. Heidän mukaan neuroverkkojen toiminnan läpinäkyvyys on tärkeää yleisen ja ammatillisen luottamuksen säilyttämisen lisäksi tärkeää myös jossain määrin koko tekoälyn kehittämisprosessille.

EU:n tietosuoja-asetuksen (GDPR) sääntöjen mukaan yksilöllä on oikeus ymmärtää, miksi malli tekee tietyn päätöksen ja mikä on yksilöä koskevien päätösten taustalla oleva mekanismi. Sääntö rajoittaa koneoppimisen hyödyntämistä kliinisessä käytössä. Tämän vuoksi on tärkeää parantaa mustan laatikon mallien selitettävyyttä ja tulkittavuutta, jotta potilaat voivat antaa asianmukaisen tietoon perustuvan suostumuksen (Rasheed ym. 2022).

5 Yhteenveto

Tässä kirjallisuuskatsauksen muodossa toteutetussa tutkielmassa oli tavoitteena tarkastella koneoppimisen soveltamista kuvantamisessa ja sen haasteita radiologiassa. Tutkielman alussa luvussa 2 esiteltiin koneoppimisen peruskäsitteitä ja erilaisia tämän tutkielman kannalta tärkeitä osia. Seuraavaksi luvussa 3 tarkasteltiin koneoppimisen soveltamista kuvantamisessa, erityisesti lääketieteellisten kuvien luokittelua, segmentointia ja rekisteröintiä. Lopuksi luvussa 4 käsiteltiin dataa ja koneoppimisen haasteisiin radiologiassa, kuten yli- ja alisovittukseen, algoritmien yleistettävyyteen ja läpinäkyvyyteen.

Tutkielmassa selvisi koneoppimisen soveltaminen kuvantamisessa on osoittautunut erittäin lupaavaksi menetelmäksi monien ongelmien ratkaisemisessa. Lääketieteellisten kuvien käsittelyssä se voi auttaa lääkäreitä nopeuttamaan diagnoosin tekemistä ja hoitamaan potilaita paremmin. Kuitenkin koneoppimisen soveltaminen radiologiassa kohtaa myös monia haasteita, kuten haasteita datan laadussa ja puutteessa, sekä algoritmien yleistettävyyteen liittyvissä ongelmissa. Näille ongelmille esiintyi kirjallisuudessa mahdollisia ratkaisuja, kuten siirrosoppimisen ja generatiivisten vastakkaisverkkojen hyödyntäminen.

Suurena haastena myös nähtiin algoritmien läpinäkyvyyteen liittyvät ongelmat. On tärkeää kehittää läpinäkyviä koneoppimismalleja joilla on kyky vastata päätöksenteko prosessiin liittyviin kysymyksiin, jotta potilaat sekä lääkärit voivat luottaa mallien tuottamiin lopputuloksiin.

Tulevaisuudessa radiologit voivat hyödyntää koneoppimista yhä enemmän, kun teknologia kehittyy ja datamäärät kasvavat. Koneoppimisen avulla radiologit voivat hyödyntää parempia diagnostisia menetelmiä ja parantaa potilaiden hoitoa. Kuitenkin on tärkeää, että koneoppimisalgoritmit kehitetään huolellisesti ja varmistetaan niiden luotettavuus ja tarkkuus.

Lähteet

- An, Fengping, Xiaowei Li ja Xingmin Ma. 2021. “Medical Image Classification algorithm based on visual attention mechanism-MCNN”. *Oxidative Medicine and Cellular Longevity* 2021:1–12.
- Balakrishnan, Guha, Amy Zhao, Mert R Sabuncu, John Guttag ja Adrian V Dalca. 2019. “Voxelmorph: a learning framework for deformable medical image registration”. *IEEE transactions on medical imaging* 38 (8): 1788–1800.
- Brady, Adrian P, ja Emanuele Neri. 2020. “Artificial intelligence in radiology—ethical considerations”. *Diagnostics* 10 (4): 231.
- Chen, Xuxin, Ximin Wang, Ke Zhang, Kar-Ming Fung, Theresa C Thai, Kathleen Moore, Robert S Mannel, Hong Liu, Bin Zheng ja Yuchen Qiu. 2022. “Recent advances and clinical applications of deep learning in medical image analysis”. *Medical Image Analysis*, 102444.
- Choy, Garry, Omid Khalilzadeh, Mark Michalski, Synho Do, Anthony E Samir, Oleg S Panykh, J Raymond Geis, Pari V Pandharipande, James A Brink ja Keith J Dreyer. 2018. “Current applications and future impact of machine learning in radiology”. *Radiology* 288 (2): 318–328.
- Eche, Thomas, Lawrence H Schwartz, Fatima-Zohra Mokrane ja Laurent Dercle. 2021. “Toward generalizability in the deployment of artificial intelligence in radiology: role of computation stress testing to overcome underspecification”. *Radiology: Artificial Intelligence* 3 (6): e210097.
- Frid-Adar, Maayan, Eyal Klang, Michal Amitai, Jacob Goldberger ja Hayit Greenspan. 2018. “Synthetic data augmentation using GAN for improved liver lesion classification”. *Teoksessa 2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018)*, 289–293. IEEE.
- Gu, Jiuxiang, Zhenhua Wang, Jason Kuen, Lianyang Ma, Amir Shahroudy, Bing Shuai, Ting Liu, Xingxing Wang, Gang Wang, Jianfei Cai ym. 2018. “Recent advances in convolutional neural networks”. *Pattern recognition* 77:354–377.

“IBM, What is machine learning?” 2023. Viitattu 21. maaliskuuta 2023. <https://www.ibm.com/topics/machine-learning>.

Jordan, M. I., ja T. M. Mitchell. 2015. “Machine learning: Trends, perspectives, and prospects”. *Science* 349 (6245): 255–260. <https://doi.org/10.1126/science.aaa8415>. eprint: <https://www.science.org/doi/pdf/10.1126/science.aaa8415>. <https://www.science.org/doi/abs/10.1126/science.aaa8415>.

L’Heureux, Alexandra, Katarina Grolinger, Hany F. Elyamany ja Miriam A. M. Capretz. 2017. “Machine Learning With Big Data: Challenges and Approaches”. *IEEE Access* 5:7776–7797. <https://doi.org/10.1109/ACCESS.2017.2696365>.

Lakhani, Paras, Adam B Prater, R Kent Hutson, Kathy P Andriole, Keith J Dreyer, Jose Morey, Luciano M Prevedello, Toshi J Clark, J Raymond Geis, Jason N Itri ym. 2018. “Machine learning in radiology: applications beyond image interpretation”. *Journal of the American College of Radiology* 15 (2): 350–359.

Li, Xiang, Mengyao Zhai ja Junding Sun. 2022. “Chapter 15 - Chest X-ray image detection for pneumonia via complex convolutional neural network and biogeography-based optimization”. Teoksessa *Multi-Chaos, Fractal and Multi-Fractional Artificial Intelligence of Different Complex Systems*, toimittanut Yeliz Karaca, Dumitru Baleanu, Yu-Dong Zhang, Osvaldo Gervasi ja Majaz Moonis, 247–262. Academic Press. ISBN: 978-0-323-90032-4. <https://doi.org/https://doi.org/10.1016/B978-0-323-90032-4.00014-6>. <https://www.sciencedirect.com/science/article/pii/B9780323900324000146>.

Li, Zewen, Fan Liu, Wenjie Yang, Shouheng Peng ja Jun Zhou. 2021. “A survey of convolutional neural networks: analysis, applications, and prospects”. *IEEE transactions on neural networks and learning systems*.

Moore, Michael M, Einat Slonimsky, Aaron D Long, Raymond W Sze ja Ramesh S Iyer. 2019. “Machine learning concepts, concerns and opportunities for a pediatric radiologist”. *Pediatric radiology* 49:509–516.

Rasheed, Khansa, Adnan Qayyum, Mohammed Ghaly, Ala Al-Fuqaha, Adeel Razi ja Junaid Qadir. 2022. “Explainable, trustworthy, and ethical machine learning for healthcare: A survey”. *Computers in Biology and Medicine*, 106043.

- Sathya, Ramadass, Annamma Abraham ym. 2013. "Comparison of supervised and unsupervised learning algorithms for pattern classification". *International Journal of Advanced Research in Artificial Intelligence* 2 (2): 34–38.
- Sharma, Neeraj, Amit K Ray, Shiru Sharma, KK Shukla, Satyajit Pradhan ja Lalit M Aggarwal. 2008. "Segmentation and classification of medical images using texture-primitive features: Application of BAM-type artificial neural network". *Journal of medical physics/Association of Medical Physicists of India* 33 (3): 119.
- Wang, Shijun, ja Ronald M Summers. 2012. "Machine learning and radiology". *Medical image analysis* 16 (5): 933–951.
- Weston, Alexander D, Panagiotis Korfiatis, Timothy L Kline, Kenneth A Philbrick, Petro Kostandy, Tomas Sakinis, Motokazu Sugimoto, Naoki Takahashi ja Bradley J Erickson. 2019. "Automated abdominal segmentation of CT scans for body composition analysis using deep learning". *Radiology* 290 (3): 669–679.
- What is Generalization in Machine Learning?* 2022. <https://deepai.space/what-is-generalization-in-machine-learning/>. Accessed: 2023-04-05.
- Wiering, Marco A, ja Martijn Van Otterlo. 2012. "Reinforcement learning". *Adaptation, learning, and optimization* 12 (3): 729.
- Willeminck, Martin J, Wojciech A Koszek, Cailin Hardell, Jie Wu, Dominik Fleischmann, Hugh Harvey, Les R Folio, Ronald M Summers, Daniel L Rubin ja Matthew P Lungren. 2020. "Preparing medical imaging data for machine learning". *Radiology* 295 (1): 4–15.
- Yadav, Samir S, ja Shivajirao M Jadhav. 2019. "Deep convolutional neural network based medical image classification for disease diagnosis". *Journal of Big data* 6 (1): 1–18.
- Zhang, Zhenwei, ja Ervin Sejdić. 2019. "Radiological images and machine learning: trends, perspectives, and prospects". *Computers in biology and medicine* 108:354–370.