

Johanna Jaatinen

TEKOÄLY PÄÄTÖKSENTEOSSA

Algoritmit, data ja yhdenvertaisuus

Informaatioteknologian ja viestinnän tiedekunta
Kandidaattitutkielma
Tammikuu 2023

TIIVISTELMÄ

Johanna Jaatinen: Tekoäly päätöksenteossa: algoritmit, data ja yhdenvertaisuus
Kandidaattitutkielma
Tampereen yliopisto
Tietojenkäsittelytieteiden tutkinto-ohjelma
Tammikuu 2023

Tekoälyn käyttö päätöksenteossa on saanut viime vuosina suurta huomiota ja se on käytössä jo esimerkiksi rahoituksessa, kunnan palveluissa ja terveydenhuollossa. Tekoäly tarjoaa monia etuja työkaluna eri aloilla, mutta siihen liittyy myös mahdollisia ongelmia, kun käyttökohteena on päätöksenteko. Tutkielmassa keskitytään tuomaan esiin tekoälyn perustaa algoritmeista ja datasta, sekä joitain sen käyttökohteita. Tutkielma pyrkii tarjoamaan vastauksen siihen, miten tekoälyä hyödynnetään ja mitä mahdollisia ongelmia siitä voi nousta.

Tutkielma on toteutettu kirjallisuuskatsauksena aiemmin julkaistuun aineistoon perustuen. Tutkielman on tarkoitus olla informatiivinen katsaus tekoälyn käyttöön päätöksenteossa, ja sisällön yhtenäisyyden vuoksi siitä on jätetty osa koneoppimisen malleista pois, kuten valvomattoman koneoppimisen vahvistusoppimismalli. Tavoitteena on tutkia tekoälyn käyttökohteita sekä sitä, millaiselle algoritmiselle perustalle se voi rakentua. Tutkimuksessa tarkastellaan erilaisia tekoälypohjaisia päätöksentekojärjestelmiä eri aloilla ja arvioidaan niiden vaikutusta päätöksentekoprosesseihin. Lisäksi tutkimuksessa analysoidaan tekoälyn eettisiä ja sosiaalisia vaikutuksia päätöksenteossa ja ehdotetaan ohjeita tekoälyn vastuulliseen käyttöön.

Tutkielma pyrkii vastaamaan kysymykseen ”Miten tekoälyä hyödynnetään päätöksenteossa ja mitä mahdollisia ongelmia siitä voi nousta?”. Tutkielma vastaa tutkimuskysymykseen tietoaineistoon perustuen, mahdollisten esiin nousevien ongelmien ollessa painottuneena vinoumiin ja sen vaikutukseen yhdenvertaisuudessa. Tuloksissa osoitetaan tekoälyn sovelluskohteita eri aloilla ja sen mahdollisia hyötyjä sekä haittoja täsmälääketieteen alalla. Tutkimustulos osoittaa myös sen, millaisia vaikutuksia datan ja algoritmien vinoumillla on tekoälyalgoritmien tekemisiin päätöksiin sekä sen, millaisia koneoppimismalleja on mahdollista hyödyntää tekoälyalgoritmien kehityksessä ohjatun ja ohjaamattoman oppimisen kautta.

Avainsanat: Tekoäly, päätöksenteko, algoritmit, data

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

SISÄLLYSLUETTELO

1	Tekoälyn käyttö päätöksenteossa.....	2
1.1	Ennakoiva analytiikka	2
1.2	Tekoälyllä tehokkaampaan riskienhallintaan	3
1.3	Asiakaspalvelua tekoälyn avulla	3
1.4	Markkinointi	4
1.5	Terveydenhuolto	4
2	Tekoälyalgoritmeista.....	5
2.1	Koneoppiminen	5
2.1.1	Ohjattu oppiminen (supervised learning)	6
2.1.2	Ohjaamaton oppiminen (unsupervised learning)	9
2.2	Syväoppiminen	11
2.3	Luonnollisen kielen käsittely (NLP)	12
3	Data ja sen käyttö tekoälyavusteisessa päätöksenteossa.....	12
3.1	Big Data	12
3.2	Datan omistajuus ja hallitseminen	13
3.3	Kerääminen ja mahdollisia ongelmia	13
3.3.1	Dataan kohdistuvat säädökset	14
3.4	Vinoumat	15
4	Yhteenveto.....	16
	Lähdeluettelo.....	17

JOHDANTO

Tekoäly on vaikuttanut monella toimialalla päätöksentekoon mahdollistamalla tarkan ja nopean datan analysoinnin ja ennusteiden tekemisen. Se on jo laajasti käytössä talouden analysoinnissa ja markkinoinnissa, ja sillä on potentiaalia parantaa hoitotuloksia ja terveydenhuollon saavutettavuutta. Suomessa tekoälyä käytetään jo tiedonlouhinnassa ja keskustelevassa tekoälyssä, esimerkkinä tästä koronapandemian aikana toteutettu HUS:in alueella toteutettu Koronabotti (HUS, 2020). Tässä tekoäly säästi henkilöstöresursseja ja mahdollisti käyttäjälle ympärivuorokautisen nopean oirearvioinnin saannin. Myös Kela käyttää automaatiota päätöksenteossaan muun muassa opintotuen myöntämisessä (Kela, 2022).

Tutkielmassa tarkastellaan tekoälyn käyttöä päätöksenteossa, sekä algoritmeihin ja dataan liittyviä kysymyksiä. Tutkielma pyrkii vastaamaan kysymykseen ”Miten tekoälyä hyödynnetään päätöksenteossa ja mitä mahdollisia ongelmia siitä voi nousta?”. Päätin tutkia tekoälyalgoritmien roolia terveydenhuollon päätöksenteossa ja siihen perustuvan datan piirteitä, sekä näihin kohdistuvia riskejä vinoumien suhteen, sillä tekoäly aiheena on ajankohtainen alalla kuin alalla. Opinnäytetyön tarkoituksena on olla informatiivinen katsaus tekoälyn käyttöön.

Tutkielma on kirjallisuuskatsaus, joka perustuu aiempiin julkaisuihin. Tietokantoina aineistoja varten on käytetty pääsääntöisesti Tampereen yliopiston Andor-tietokantaa ja Google Scholaria, mutta käytössä on ollut myös O'Reilly, SpringerLink ja muita, kuten Kelan, John Hopkins Medicinen, Babylon Healthin, HUS:in ja Eulariksen verkkosivut. Pääosin tutkielmassa käytetty aineisto on julkaistu 2010-vuoden jälkeen.

Ensimmäisessä luvussa käsitellään tekoälyn käyttöä yleisesti. Toisessa luvussa tarkastellaan tarkemmin tekoälyalgoritmeja ja niiden toimintaa, jotta niiden arviointi olisi mahdollista. Tarkastelin huolellisesti tutkielmani aiheen laajuutta ja päätin keskittyä tiettyihin näkökulmiin, jotka ovat saaneet eniten tutkimusta ja huomiota käyttämissäni lähteissä. Vaikka vahvistusoppiminen on kiinnostava aihe, en sisällyttänyt sitä tutkielmani toiseen lukuun, koska se ei ole ollut keskeisessä roolissa käyttämissäni lähteissä. Kolmannessa luvussa keskitytään datan omistajuuteen ja hallintaan, sekä datankeruuseen liittyviin eettisiin ja laillisiin kysymyksiin, kuten yksityisyydensuojaan.

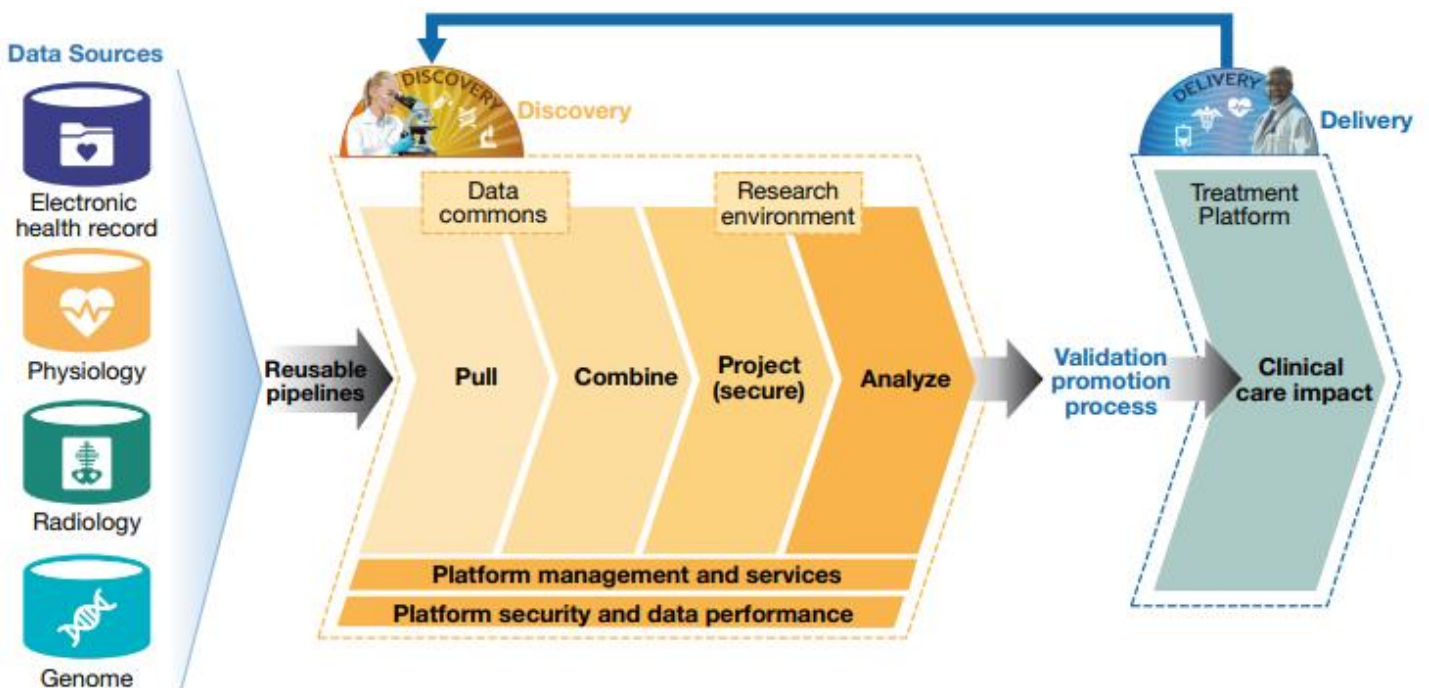
1 Tekoälyn käyttö päätöksenteossa

Hyödyntämällä koneoppimisalgoritmeja tekoälypohjaiset päätöksentekojärjestelmät voivat analysoida valtavia määriä dataa, tunnistaa malleja ja luoda ennusteita, joita käyttäjät voidaan käyttää edelleen päätöksenteossa. Tekoälyä voidaan soveltaa monille eri aloille ja tunnetuimpia esimerkkejä näistä lienee asiakaspalvelussa käytetyt chatbotit tai markkinoinnissa käytetyt analytiikkajärjestelmät, tai vaikka monien viihdepalveluiden käyttämät suosittelujärjestelmät.

1.1 Ennakoiva analytiikka

Yksi merkittävimmistä tekoälyn ja datatieteen sovelluksista päätöksenteossa on ennustava analytiikka, jossa ennakoivat analytiikkajärjestelmät käyttävät aiemmin kerättyä dataa muodostaessaan ennusteita eri asioista. Tällaisia järjestelmiä on käytössä esimerkiksi terveydenhuollossa ja ne voivat analysoida potilastietoja monia tilastollisia menetelmiä tehokkaammin ennustaakseen, mitkä hoidot voisivat olla tehokkaampia tai millä potilailla on suurempi riski saada tiettyjä sairauksia (Ramesh, Umesh Kumar, Poongodi, Sarita, Amandeep & Mounir, 2022).

Ennakoivassa analyysissä tekoälyllä toimivat poikkeamien havaitsemismallit voivat analysoida suuria määriä dataa ja tunnistaa malleja ja trendejä, jotka ovat epänormaaleja tai odottamattomia (Rawat & Yadav, 2021). Näitä tietoja voidaan jalostaa edelleen mahdollisten riskien tai mahdollisuuksien tunnistamiseen ja tulevien tulosten ennustamisessa.



Kuva 1.1 Johns Hopkins Precision Medicine Analytics Platform (Ravitz, 2021).

Esimerkkinä tästä on yllä esitetystä kuvassa John Hopkins-instituutin Precision Medicine Analytics Platform, jonka tavoitteena on kerätä ja yhdistää dataa eri lähteistä tekoälyalgoritmien ja luonnollisen kielen käsittelyjärjestelmille (Ravitz, 2021). Precision Medicine Analytics Platform (PMAP) antaa tutkijoille mahdollisuuden koota ja analysoida potilastietoja useista Johns Hopkins Medicine -järjestelmistä tutkimustarkoituksiin (Ravitz, 2021). PMAP:in tapauksessa järjestelmä ei siis suoraan itse ohjaa hoidon toteutusta, vaan ihminen on yhä tärkeä osa sen toimintaa.

1.2 Tekoälyllä tehokkaampaan riskienhallintaan

Tekoälypohjaiset riskinhallintajärjestelmät voivat tunnistaa ja analysoida mahdollisia riskejä ja tarjota yrityksille suosituksia näiden riskien vähentämiseksi. Keinotekoiset neuroverkot (Artificial neural networks) ovat tekoälyn komponentteja ja niiden avulla voidaan paikantaa riskienhallinnan kannalta kiinnostavia datapisteitä tehokkaasti (Faraj Al-Janabi & Saeed, 2011).

Tekoälypohjaisia riskinhallintajärjestelmiä käytetään myös terveydenhuollossa. PMAP:in kaltaiset järjestelmät voivat analysoida potilastietoja mahdollisten terveystilaisuuksien tunnistamiseksi ja ehkäisy-suunnitelmien kehittämiseksi (Ravitz, 2021).

Keinotekoisien neuroverkkojen avulla voidaan myös ennustaa todennäköisyyttä sille, millä todennäköisyydellä hoidossa ollut henkilö palaa takaisin sairaalaan hoidettavaksi 30 päivän sisään (Jamei, Nisnevich, Wetchler, Sudat & Liu, 2016). Tätä voi käyttää esimerkiksi terveydenhuollossa käytettävästä riskienhallinta-arvioinnista, sillä hoitokierreet rasittavat muun muassa terveydenhoitojärjestelmän henkilöstö- ja terveydenhoitoresursseja.

1.3 Asiakaspalvelua tekoälyn avulla

Tekoälyllä toimivat chatbotit ja virtuaaliset avustajat ovat tulossa yhä suosittumiksi asiakaspalvelussa ja ovat hyvä esimerkki tekstianalytiikasta. Nämä järjestelmät voivat tarjota asiakkaille henkilökohtaisia suosituksia ja apua, mikä vähentää inhimillisen tuen tarvetta. Chatbottien ja virtuaaliassistenttien lisäksi tekstianalytiikkaa voidaan käyttää myös tiedonlouhintaan erilaisilta sivuilta, kuten online-foorumeilta ja yritysdokumenteista tai asiakaspalautteista (Rawat & Yadav, 2021).

Yksi esimerkki yrityksestä, joka käyttää tekoälyä terveydenhuollon asiakaspalvelussa, on Babylon Health. Babylon Health on brittiläinen terveystaloyritys, joka tarjoaa verkkokonsultaatiopalveluita potilaille ympäri maailmaa. Sen tekoälyjärjestelmä kykenee diagnosoimaan yli 1 000 yleistä sairautta ja ohjaamaan potilaat tarvittaessa lääkärille (Babylon Health, n.d.). Järjestelmä pystyy myös vastaamaan potilaiden kysymyksiin terveyteen ja hyvinvointiin liittyen, sekä tarjoamaan ravitsemus- ja liikuntaohjeita.

Lisäksi Babylon Healthin tekoälyjärjestelmä analysoi potilaiden oireita ja vertaa niitä klinisiin tietokantoihin. Järjestelmä kerää myös käyttäjän aiempaa terveyshistoriaa tietokantansa laajentamiseen, jolloin yrityksen pitää myös huolehtia dataan liittyvistä säädöksistä, joita käsittelen hiukan myöhemmin. (Babylon Health, n.d.)

Babylon Healthin tapaisten tekoälyalgoritmien käytöstä on tehty tutkimusta niiden tarkkuuden arvioinnissa. Eräässä vuonna 2020 tehdystä tutkimuksesta vertailtiin kahdeksan eri sovelluksen ja seitsemän lääkärin ryhmän tekemiä päätöksiä keskenään (Gilbert et al, 2020). Gilbertin ja muiden (2020) tutkimuksen mukaan tekoälyn tekemät arviot olivat joidenkin sovelluksien kohdalla lähellä lääkärin tekemiä arvioita. Tästä voi johtaa sen ajatuksen, että tekoäly ei ole valmis korvaamaan ammattilaisia, vaan sitä voidaan käyttää työkaluna tietyissä tilanteissa.

1.4 Markkinointi

Tekoälypohjaiset markkinointijärjestelmät voivat analysoida asiakastietoja tunnistukseen potentiaalisia asiakkaita ja luodakseen kohdennettuja markkinointikampanjoita, esimerkiksi verkkokaupassa nämä järjestelmät voivat analysoida selaus- ja ostohistoriaa tarjotakseen henkilökohtaisia suosituksia.

Kun ajattelee tekoälypohjaisia markkinajärjestelmiä, saattaa mieleen tulla ensimmäisenä kohdennettu mainonta esimerkiksi verkkokauppojen tuote-ehdotuksissa tai viihdepalvelujen sisältöehdotuksissa, mutta myös lääketeollisuudessa on mahdollista hyötyä näistä järjestelmistä. Bates kirjoittaa Eulariksen virallisella verkkosivulla siitä, miten tekoälyn avulla lääkemyynnin työntekijät voivat tunnistaa mahdollisia asiakkaita tehokkaammin ennakoivan mallintamisen avulla, esimerkiksi tarkentamalla tietyn alueen spesialisteja. Tällöin voidaan analysoida sitä, ketkä tietyn alueen asiakaskunnasta olisivat mahdollisesti kiinnostuneita tarjolla olevasta lääkkeestä (Bates, n.d). Kuten täsmälääketieteen kohdalla, myös lääkemyynnissä kohdennetusta palvelusta on etua, kun tiedetään mahdollisen asiakkaan mieltymyksistä ja tarpeista enemmän (Bates, n.d).

1.5 Terveysthuolto

Tekoälyllä toimivat terveydenhuoltojärjestelmät voivat analysoida potilastietoja diagnoosien ja hoitosuunnitelmien laatimiseksi. Nämä järjestelmät voivat myös analysoida väestön terveystietoja mahdollisten terveystieteiden tunnistamiseksi ja ehkäisystrategioiden kehittämiseksi (Jamei et al., 2016). Terveysthuollossa tekoälyllä on laajalti käytösmahdollisuuksia ja aikaisemmin tässä luvussa on esitelty esimerkkejä tekoälyn käytöstä eri terveydenhuollollisissa käyttökohteissa.

Tekoälyn käyttö ei kuitenkaan ole poistanut käyttäjän roolia päätöksentekoprosessista, vaan tehostanut päätöksentekijän työtä. John Hopkins Medicinen PMAP pyrkii edistämään terveydenhuollon ammattilaisten osaamista, jolla tehostettaisiin alan kehitystä jatkuvan oppimisen kautta (Ravitz, 2021).

Sen tarkoituksena ei ole poistaa ammattilaisen vastuuta päätöksenteossa, vaan tukea sitä ja samalla pyrkimyksenä on edistää lääketieteen kehitystä. Terveystieteiden ammattilaisen rooli on yhä hoidossa ja siihen liittyvissä asioissa, vaikka käytettäisiinkin PMAP:in kaltaisia työkaluja (Ravitz, 2021).



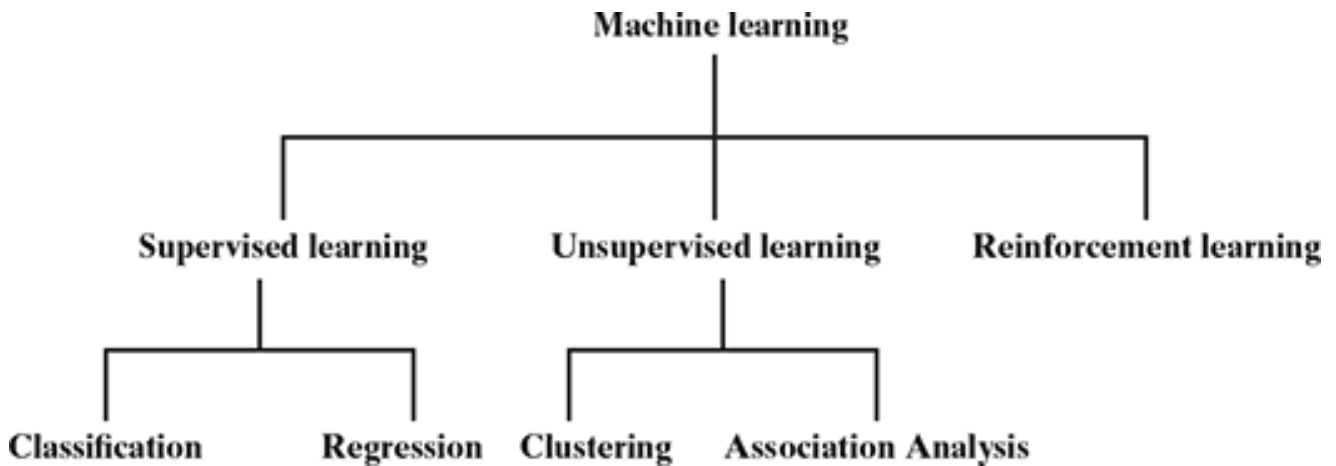
Kuva 1.2 John Hopkins Medicinen malli (Ravitz, 2021).

2 Tekoälyalgoritmeista

2.1 Koneoppiminen

Koneoppiminen (machine learning) on tekoälyn haara, joka perustuu tietokoneohjelmien oppimiseen datasta automaattisesti ilman, että niille annetaan nimenomaisia ohjeita. Koneoppimisessa tietokoneohjelmat oppivat tunnistamaan kaavoja, rakenteita ja ominaisuuksia datasta, jota niille syötetään. Koneoppimisalgoritmit opettavat tietokoneelle tunnistamaan yhteyksiä datassa, jolloin tietokone kykenee tekemään ennusteita tai tekemään päätöksiä uusien syötteiden perusteella (Chandramouli, Dutt & Das, 2018, 1.4).

Koneoppiminen voidaan jakaa kolmeen pääluokkaan sen mukaan, millainen oppimistahtuma on. Ohjatussa oppimisessa opetetaan tietokonetta ennakoimaan oikea vastaus esimerkkien avulla, kun taas ohjaamattomassa oppimisessä tietokone löytää ominaisuuksia ja rakenteita datasta ilman nimenomaista ohjausta tai vastauksia. Alla oleva kaavio kirjasta Machine Learning (Chandramouli et al., 2018, 1.4) havainnollistaa hyvin koneoppimisen päätyypit. Käsittelemme kaavion esittämiä valvotun ja valvomattoman oppimisen malleista muita, paitsi vahvistusoppimista (reinforcement learning).



Kuva 2.1 Esitys koneoppimisen päätyypeistä (Chandramouli et al., 2018, 1.4).

2.1.1 Ohjattu oppiminen (supervised learning)

Ohjatussa oppimisessa tietokoneelle syötetään esimerkkidataa, jossa kuhunkin syötteeseen liittyy tietty oikea vastaus. Tietokone oppii ennustamaan vastauksia uusille syötteille näiden esimerkkien perusteella (Chandramouli et al., 2018, 1.5). Esimerkiksi kuvantunnistuksessa ohjattu oppiminen tarkoittaa sitä, että tietokoneelle syötetään kuvia, joihin on liitetty oikeat vastaukset harjoitteluvaiheessa, ja sen jälkeen se toteuttaa arvioita niihin perustuen.

Vuonna 2018 Journal of Digital Imaging-lehdessä julkaistu artikkeli (Lakhani, Gray, Pett, Nagy & Shih, 2018) esitti yksinkertaistetun esimerkkiohjelman lääketieteellisestä kuvantamisesta, jossa koodin tehtävänä oli ennustaa, onko kuva rintakehän vai vatsanseudun röntgenkuva. Seuraavalla sivulla on artikkelissa esitetty kuva selitetystä koodista, jossa tehdään päätelmiä testitapauksista ja esitetään ennusteet analysoitavien kuvien kanssa.

```
# import numpy and keras preprocessing libraries
import numpy as np
from keras.preprocessing import image

# load, resize, and display test images
img_path='../data/test/chest_test_001.png'
img_path2='../data/test/abd_test_001.png'
img = image.load_img(img_path, target_size=(img_width, img_height))
img2 = image.load_img(img_path2, target_size=(img_width, img_height))
plt.imshow(img)
plt.show()

# convert image to numpy array, so Keras can render a prediction
img = image.img_to_array(img)

# expand array from 3 dimensions (height, width, channels) to 4 dimensions (batch size,
height, width, channels)
# rescale pixel values to 0-1
x = np.expand_dims(img, axis=0) * 1./255

# get prediction on test image
score = model.predict(x)
print('Predicted:', score, 'Chest X-ray' if score < 0.5 else 'Abd X-ray')

# display and render a prediction for the 2nd image
plt.imshow(img2)
plt.show()
img2 = image.img_to_array(img2)
x = np.expand_dims(img2, axis=0) * 1./255
score2 = model.predict(x)
print('Predicted:', score2, 'Chest X-ray' if score2 < 0.5 else 'Abd X-ray')
```

Kuva 2.2 Hello World Deep Learning in Medical Imaging-artikkelin kuva (Lakhani et al., 2018)



Predicted: [[0.00007]] Chest X-ray



Predicted: [[0.99823]] Abd X-ray

Kuva 2.3 Jos hakasuluissa oleva arvo on pienempi kuin 0.5, kuva on rintakehästä, muutoin vatsan seudusta. (Lakhani et al., 2018).

Lakhanin ja muiden (2018) artikkelissa on kyseessä mallin esiopetuksesta, joka on koneoppimisen tekniikka ja ohjattua opetusta. Siirrosoppimisessa otetaan käyttöön ennakkoon koulutetun koneoppimismallin oleelliset osat ja sovelletaan niitä uuteen, mutta samankaltaiseen ongelmaan. Yleensä tämä sisältää mallin ydininformaation, joka mahdollistaa sen toiminnan, ja siihen lisätään uusia osia, jotta malli voi ratkaista tietyn tehtävän (Lakhani et al., 2018).

2.1.1.1 Luokittelu

Valvotussa koneoppimisessa luokittelu tarkoittaa sitä, että koneoppimismalli pyrkii oppimaan ennustamaan uusien havaintojen luokkia, eli kategorioita, valmiiksi luokitellun harjoitusdatan perusteella. Tämä tapahtuu niin, että malli oppii tunnistamaan havaintojen ominaisuuksista sellaisia piirteitä, jotka korreloivat tietyllä tavalla havaintojen luokan kanssa (Chandramouli et al., 2018, 1.5). Kun malli on koulutettu tarpeeksi hyvin, se pystyy ennustamaan uusien havaintojen luokan näiden ominaisuuksien perusteella.

Luokittelu on yksi yleisimmistä valvotun oppimisen tehtävistä ja sillä on laaja käyttö sovellusalueilla, kuten kuvantunnistuksessa ja luonnollisen kielen käsittelyssä (Chandramouli et al., 2018, 1.5). Ylempänä esitetty ohjelmassa käytetään luokittelua, jossa kuvia luokitellaan ennustearvojen mukaan joko rintakehä- tai vatsanseturönteen.

2.1.1.2 Regressio

Regressioanalyysi on valvotun koneoppimisen alakenttä, joka pyrkii mallintamaan suhteen tietyn määrän ominaisuuksien ja jatkuvan kohde- muuttujan välillä (Chandramouli et al., 2018, 1.5). Se tarkoittaa sitä, että koneoppimismalli pyrkii oppimaan ennustamaan numeerisia arvoja uusille havainnoille harjoitusdatan perusteella. Regressiomallin tavoitteena on löytää funktio, joka kuvaa havaintojen ominaisuuksia ja niiden vastaavia numeerisia arvoja.

Tämän funktion avulla malli pystyy ennustamaan uusien havaintojen arvoja näiden ominaisuuksien perusteella (Chandramouli et al., 2018, 1.5). Regressio-ongelmissa pyritään löytämään kvantitatiivinen vastaus, kuten ennustamaan talon hinta tai arvioimaan sekuntimäärä, jonka joku viettää videota katsellen.

Chandramoulin ja muiden (2018) kirjassa esitetään tyypillinen yksinkertainen regressiomalli, mutta regressioanalyysin menetelmiä on muitakin, kuten logistinen regressio, polynomiregressio ja monimuuttujaregressio. Näiden menetelmien valinta riippuu ongelman tyypistä ja siitä, millaisia muuttujia käytetään ennustamisessa.

2.1.2 Ohjaamaton oppiminen (unsupervised learning)

Ohjaamattomassa oppimisessa tietokoneelle syötetään vain dataa, johon ei ole liitetty tiettyjä vastauksia. Toisin kuin valvotussa oppimisessa, valvomattomassa oppimisessa ei ole merkittävää koulutusdataa, josta oppia eikä ennustuksia, joita tehdä (Chandramouli et al., 2018, 1.5). Valvomattoman oppimisen tavoitteena on ottaa aineisto syötteeksi ja yrittää löytää luonnollisia ryhmittymiä tai kuvioita tietueiden tai tietoelementtien sisällä.

2.1.2.1 Klusterointi eli ryhmittely

Klusterointi on yleisin ohjaamattoman oppimisen tavoista, joka tarkoittaa samanlaisten tietopisteiden ryhmittelyn eri rypäisiin tai alaryhmiin niiden ominaisuuksien tai ominaisuuksien perusteella (Chandramouli et al., 2018, 1.5). Ryhmittelyn perusideana on tunnistaa keskenään samankaltaisia tietopisteryhmiä jonkin samankaltaisuusarvon tai etäisyyden perusteella. Ryhmittelyssä samankaltaisuus riippuu annetusta tehtävästä ja yksi esimerkki ryhmittelyä käyttävästä algoritmeista on hierarkkinen ryhmittely ja K-keskiarvoryhmittely.

K-keskiarvoryhmittelyalgoritmi on yksi yleisimmistä datankeruualgoritmeista ja sitä käytetään isojen datamäärien ryhmittelyyn (Na, Xumin & Yong, 2019). Kyseessä on ositusalgoritmi, joka jakaa tietoaineiston k-määrään klustereita samankaltaisuuden perusteella, ja muissa klustereissa olevat ovat vähemmän samankaltaisia. K-keskiarvoryhmittely pyrkii minimoimaan etäisyydet klusterin sisällä ja maksimoimaan etäisyydet eri klustereiden välillä (Na et al., 2019).

Jain ja Dubesin tekemän määrittelyn mukaan hierarkkinen klusterointimetodi on toimenpide etäisyysmatriisin muuttamiseksi sisäkkäisten osituksien sarjaksi. Hierarkkinen klusterointi rakentaa klustereiden hierarkiaa yhdistämällä tai jakamalla klustereita iteratiivisesti niiden samankaltaisuuksien perusteella monitasoisin rakenteisiin. Tuloksena on puumainen rakenne, joka näyttää klusterien väliset suhteet (Jain & Dubes, 1988). Hierarkkisesta ryhmittelystä hyvin käytännön esimerkkinä voisi pitää tietokoneen kovallevyn kansiojärjestelyä.

2.1.2.2 Assosiaatioanalyysi

Assosiaatioanalyysi on ryhmittelyn tapaisesti ohjaamattoman koneoppimisen alalaji. Ryhmittelyn tapaan assosiaatioanalyysi perustuu erilaisten mallien löytämiseen tietoa-aineistosta, mutta se eroaa ryhmittelystä tavoitteissa ja lähestymistavassa.

Assosiaatioanalyysiä käytetään etsimään toistuvia kohteiden tai tapahtumien samanaikaisia esiintymisiä tietojoukosta, ja tavoitteena on löytää piilotettuja assosiaatioita niiden välillä. Sitä käytetään yleisesti suositusjärjestelmissä, joissa sen avulla voidaan ehdottaa liittyviä tuotteita asiakkaille heidän aiemman ostohistoriansa perusteella. Assosiaatioanalyysi tuottaa tyypillisesti säännöt muodossa "jos A niin B", jossa A ja B ovat kohteita tai tapahtumia, jotka esiintyvät yhdessä tietojoukossa. (Chandramouli et al., 2018, 1.5).

Erään vuonna 2021 toteutetun tutkimuksen tekemän ehdotuksen mukaan assosiaatioanalyysillä voitaisiin tehostaa terveydenhuollossa käytettävien ohjelmien tuottaman tiedon ymmärrettävyyttä (Butryn, Chomiak-Orsa, Hauke, Pondel & Siennicka, 2021). Tutkimuksen pääasiallinen tavoite on ehdottaa menetelmää riskiryhmien tunnistamiseksi, jotta potilaille voidaan tarjota tarvittava interventio. Tutkimuksen tietoaineisto koostui erilaisista henkilö- ja terveystiedoista, kuten sukupuolesta, iästä, parisuhdestatuksesta ja tiedosta aiemmasta sydän- tai verisuonitaudista. Alla olevassa kaaviossa on tarkemmin eritelty tietoaineiston attribuutit.

Taulukko 2.4 Tutkittavat attribuutit (Butryn et al., 2021).

Attribuutti	Kuvaus	Tietotyyppi
id	Yksilöllinen tunniste	Laadullinen
sukupuoli	"Mies", "Nainen" tai "Muu"	Laadullinen
ikä	Potilaan ikä	Laadullinen
hypertensio	0, jos potilaalla ei ole verenpainetautiä, 1, jos potilaalla on verenpainetauti	Määrällinen
sydänsairaus	0, jos potilaalla ei ole sydänsairautta, 1, jos potilaalla on sydänsairaus	Määrällinen
naimisissa	"Ei" tai "Kyllä"	Laadullinen
työtyyppi	"lapset", "valtion työ", "ei koskaan työskennellyt", "yksityinen" tai "itsensä työllistänyt"	Laadullinen
asuinalue	"Maaseutu" tai "Kaupunki"	Laadullinen
Ka_glukoo- sitaso	Keskimääräinen veren glukoositaso	Laadullinen
bmi	Kehon massaindeksi	Laadullinen
tupakointi	"entinen tupakoitsija", "ei koskaan tupakoinut", "tupakoi" tai "tuntematon"*	Laadullinen
aivohalvaus	1 jos potilaalla on ollut aivohalvaus, 0 jos ei.	Binääri-

Butrynin ja muiden (Butryn et al., 2021) tutkimus on esimerkki assosiaatioanalyysistä ja siinä arvioidaan eri tekijöiden yhteyksiä todennäköisyyksien avulla. Tutkimuksessa teh-

tiin valikointia korkeimpiin nostearvoihin perustuen, jotta voitiin tarkentaa relevanteimmat assosiaatiot. Tutkimuksessa esitetyssä koneoppimisen mallissa attribuuttien perusteella muodostettiin assosiaatiosääntöjä. Mallin avulla voitiin tuottaa paljon erilaisia assosiaatiosääntöjä ja tilastollisia luotettavuusarvioita näistä, kuten esimerkiksi korkean iän ja yksityisen sektorin työpaikan tilastollista todennäköisyyttä aivohalvauksen riskitekijöinä.

Taulukko 2.3 Tutkimuksen säännöt korkeimmalla nostearvolla, joiden tuki on yli 0,01. Nostearvolla tarkoitetaan oletettujen seurausten todennäköisyyttä silloin, kun oletetut syyt ilmenevät, suhteessa siihen kuinka usein oletetut seuraukset ilmenevät yleisesti tietoaaineistossa (Butryn et al., 2021).

Sääntö ID	Oletetut syyt ilmiölle	Oletettu seuraus ilmiölle	Syiden esiintyvyys	Seurausten esiintyvyys	Syyt + seuraukset esiintyvyys	Todennäköisyys seurauksille, kun syyt esiintyvät	Noste
3746	(ikä_korkea, työtyyppi_yksityinen)	(aivohalvaus)	0.065753	0.048728	0.014090	0.214286	4.397590
46600	(ei_sydänsairaus, ikä_korkea, työtyyppi_yksityinen)	(aivohalvaus)	0.052250	0.048728	0.010959	0.209738	4.304258
46432	(ei_korkea_verenpaine, ikä_korkea, työtyyppi_yksityinen)	(aivohalvaus)	0.050294	0.048728	0.010372	0.206226	4.232182

2.2 Syväoppiminen

Syväoppimisella tarkoitetaan koneoppimisen alalajia, ja tekoälyn tyyppiä, joka imitoi toiminnassaan ihmisen oppimista tietyissä tilanteissa. Syväoppiminen on tekoälyn osa-alue, joka perustuu syvien neuroverkkojen käyttöön. Syvät neuroverkot ovat hierarkkisia rakenteita, jotka rakentuvat yksittäisistä neuroverkoista. Jokainen neuroverkko käsittelee eri ominaisuuksia, kuten pikselien arvoja kuvatiedostoissa, sanojen esiintymistä tekstitiedostoissa tai ääniaaltojen piirteitä puheen tunnistuksessa.

Neuroverkkoihin liittyy yritys ja erehdys -prosessi, joten algoritmien opetukseen tarvitaan suuri määrä dataa. Koska mallin muutamat ensimmäiset iteraatiot sisältävät jonkin verran valistuneita arvauksia kuvan tai puheen osien sisällöstä, harjoitusvaiheessa käytetyt tiedot täytyy merkitä, jotta malli voi nähdä, oliko sen arvaus oikea. Tämä tarkoittaa

sitä, että vaikka monilla big dataa käyttävillä yrityksillä on suuria tietomääriä, jäsentämätön data on vähemmän hyödyllistä. Strukturoimatonta dataa voidaan analysoida syväoppimismallilla vain, kun se on koulutettu ja saavuttanut hyväksyttävän tarkkuustason, mutta syväoppimismallit eivät voi harjoitella jäsentämättömällä tiedolla. käsittelyn (Aggrawal, 2018, s.106).

Syväoppiminen on siis uusi nimitys suurelle määrälle neuroverkkoja, jotka pyrkivät ihmisen hermoston tapaiseen, monitasoiseen tiedonprosessointiin ja oppimiseen (Aggrawal, 2018, s.21). Tämän takia syväoppimisesta voi lukea englannin kielellä myös nimellä *deep neural learning* tai *deep neural networking*.

Aggrawal kirjoittaa, että syväoppiminen on koneoppimista suurille datamäärille, jotka vaativat monitasoista ja hierarkkista käsittelyä (2018). Pienemmille tietoaisteistoille perinteinen koneoppiminen voi olla parempi vaihtoehto tehokkuuden suhteen. Teknologian kehitys, esimerkiksi parempien grafiikkaprosessorien kehitys, on edesauttanut entistä suurempien tietoaisteistojen käsittelyn (Aggrawal, 2018, s.24). Ei ole sattumaa, että hermoverkkoista tuli suosittuja vasta sen jälkeen, kun big data-analytiikalle nousi isompi yhteiskunnallinen tarve.

2.3 Luonnollisen kielen käsittely (NLP)

Tekoälypohjaista ennustavaa analyysiä käytetään myös luonnollisen kielen käsittelyssä (NLP). Luonnollisen kielen käsittely (NLP) on tutkimusala, joka keskittyy opettamaan tietokoneita ymmärtämään ja tulkitsemaan ihmisten kieltä. Ennakoivassa analyysissä NLP-malleja voidaan käyttää analysoimaan jäsentämätöntä dataa, kuten asiakasarvosteluja tai sosiaalisen median viestejä, ja tunnistamaan näiden tietojen malleja ja trendejä.

Näitä tietoja voidaan jatkojalostaa ennusteiden tekemiseen asiakkaiden käyttäytymisestä. Babylon Healthin AI käyttää luonnollisen kielen käsittelyä kerätessään tietoa lääketieteellisistä tietoaisteistoista (Babylon Health, n.d.). Myös John Hopkinsin PMAP käyttää luonnollisen kielen käsittelyä jäsentämättömien tekstien analysoinnissa (Ravitz, 2021). Luonnollisen kielen käsittely voi olla ohjaamatonta tai ohjattua oppimista, sillä se ei ole koneoppimisen ongelma vaan enemmänkin datan käsittelyyn liittyvä tekoälyn alalaji ja sitä voidaan toteuttaa yllä esitetyillä malleilla, olivat ne ohjattuja tai ohjaamattomia.

3 Data ja sen käyttö tekoälyavusteisessa päätöksenteossa

3.1 Big Data

Big Data tietoaisteistot ovat suuria, nopeasti kasvavia ja monimuotoisia tietovarantoja, joiden käsittelyyn vaaditaan kehittyneempiä analysointi- ja prosessointitapoja (Rawat & Yadav, 2021). Ravitz (2018) kirjoittaa artikkelissaan, että tätä suurta määrää dataa käytetään terveydenhuollossa monin tavoin, kuten potilaiden hoidon ja hyvinvoinnin parantamiseen, kustannusten hallintaan ja sairauksien ehkäisyyn. Sitä voidaan myös käyttää potilaiden hoitokokemuksen parantamiseen, kuten hoitoprosessin optimointiin täsmälääketieteessä.

Big Datan analyysiin voidaan käyttää aiemmassa luvussa käsiteltyjä koneoppimisen malleja. John Hopkinsin kehittämä Precision Medicine Analytics Platform on mielestäni tästä hyvä esimerkki, joka kerää dataa monesta eri lähteestä ja yhdistää tietoja käyttäjälle paremmin ymmärrettäväksi kokonaisuudeksi, soveltamalla esimerkiksi NLP:ää (Ravitz, 2021, katso kuva 1.1). Tämän avulla käyttäjät voivat ottaa huomioon

3.2 Datan omistajuus ja hallitseminen

Tässä tutkielmassa on aiemmin käsitelty tekoälyä ja siihen perustuvaa dataa. Tästä voi-kin herätä kysymys siitä, kuka kertyvää dataa omistaa. Datan omistajuutta voi ajatella hiukan mustavalkoisesti samalla tavalla kuin minkä tahansa muun asian omistamisen, jolloin sen omistajalla on täysi valta kaikkeen siihen liittyvään, kuten käyttöön ja jakamiseen (Fadler & Legner, 2020).

Laillisesta näkökulmasta katsottuna datan omistajuus assosioidaan yksilön yksityisyyteen ja siihen, miten paljon kontrollia tiedon kohteilla on, kun taas hallinnollisella puolella datan omistusoikeudet ovat tärkeitä yritysten toiminnan kannalta. Tietojärjestelmien kannalta datan omistajuudella ei tarkoiteta omistusoikeuksia, vaan enemmänkin päätöksenteon hallinnan oikeuksia (Fadler & Legner, 2020). Datan omistajuudelle ei ole olemassa täydellisen tarkkaa määritelmää ja sen määritelmä myös riippuu siitä, toimiiko yksilö vai yritys datan omistajana. Datan omistajuuden ja yksityisyyden määritelmään liittyy myös se, että useimmilla mailla on omat lainsäädännöt ja suositukset näitä koskien (Scassa, 2018). Yksityisyyden ja omistajuuden taso voi vaihdella huomattavastikin riippuen maiden oikeusjärjestelmistä, kulttuurillisista arvoista ja poliittisesta ympäristöstä.

3.3 Kerääminen ja mahdollisia ongelmia

Tiedonkeruu on prosessi, jossa kerätään tietoa eri lähteistä ja tallennetaan se jatkoanalyysiä tai käyttöä varten. Vaikka tiedonkeruu voi tarjota arvokkaita näkemyksiä ja etuja, se voi aiheuttaa myös useita ongelmia. Datan keräämiseen liittyy myös joitain haasteita ja riskejä, jotka liittyvät jo aiemmin käsiteltyihin vinoumiin tietoaaineistossa, mutta myös tietoturvariskeihin ja eettisiin kysymyksiin.

1. Tietoturvaongelmat: Kun dataa kerätään useista lähteistä, se voi olla alttiina tietoturvaongelmille, kuten tietomurroille tai tietojen väärinkäytölle. Yksi tiedonkeruun tärkeimmistä kysymyksistä on tietosuoja (Rawat & Yadav, 2021). Kerätyt tiedot voivat sisältää arkaluonteisia tietoja, kuten henkilötietoja, terveys- tai taloustietoja, jotka voivat johtaa tietosuojaloukkauksiin, jos niitä ei käsitellä asianmukaisesti.
2. Laadun ongelmat: Kerätyn datan laatu voi olla epätarkkaa tai puutteellista, mikä voi vaikuttaa sen hyödyntämiseen päätöksenteossa tai analyysissa (Rawat & Yadav, 2021). Datan laatuun liittyvät ongelmat vaikuttavat algoritmien ja mallien toimintaan ja tietoaaineiston vinoumaan. Datan puutteellisuus voi johtaa kokonaisvaltaiseen vinoumaan (Obermeyer et al.,2020).

3. Tietoaineiston puolueellisuus: Datan puolueellisuus on systemaattinen virhe tiedon keräämisessä, analysoinnissa tai tulkinnassa, joka voi johtaa vääriin tai epäreiluihin ennusteisiin. Tietoaineisto voi vääristyä monesta eri tekijästä tai syystä johtuen (Norori, Hu, Aellen, Faraci & Tzovara, 2021).
4. Eettiset ja lailliset kysymykset: Datan kerääminen voi herättää eettisiä kysymyksiä, kuten yksityisyyden suojaan ja tietojen käyttöön liittyviä kysymyksiä. Tähän tarkoitukseen on kehitetty erilaisia maiden välisiä standardeja ja säädöksiä, kuten Euroopan unionin kehittämä GDPR (European Parliamentary Research Service, 2020).

3.3.1 Dataan kohdistuvat säädökset

Yleisellä tietosuoja-asetuksella (GDPR) voi olla vaikutusta tekoälyn (AI) päätöksentekoon, koska tekoälyalgoritmit käyttävät usein suuria määriä henkilötietoja oppiakseen ja tehdäkseen päätöksiä. GDPR määrää, että henkilötiedot on kerättävä ja käsiteltävä laillisella, oikeudenmukaisella ja läpinäkyvällä tavalla ja yksilöille on kerrottava, kuinka heidän tietojaan käytetään (European Parliamentary Research Service, 2020). Tämä tarkoittaa, että tekoälyjärjestelmät on suunniteltava GDPR:n tietosuojaperiaatteiden mukaisesti.

GDPR:n mukaan henkilöllä on oikeus päästä käsiksi ja oikaista henkilötietojaan sekä oikeus tulla unohdetuksi, mikä tarkoittaa, että he voivat pyytää tietojensa poistamista yrityksen rekisteristä (European Parliamentary Research Service, 2020). Tämä voi olla haaste tekoälyjärjestelmille, koska ne ovat saattaneet sisällyttää henkilötietoja päätöksentekoprosesseihinsa (Ravitz, 2021; Rawat & Yadav, 2020). Tekoälyä käyttävien yritysten on varmistettava, että ne voivat tarjota yksilöille mahdollisuuden käyttää näitä oikeuksia, mikä voi edellyttää mekanismien kehittämistä tekoälyalgoritmeihin sisällytettyjen henkilötietojen poistamiseksi tai anonymisoimiseksi (European Parliamentary Research Service, 2020)..

Lisäksi GDPR edellyttää, että kaiken automaattisen päätöksenteon, mukaan lukien tekoälyn tekemät päätökset, on oltava oikeudenmukaista, läpinäkyvää ja selitettävissä. Tämä tarkoittaa, että yksilöiden on kyettävä ymmärtämään, miten heihin vaikuttavat päätökset tehtiin, ja kyseenalaistamaan päätökset, jotka he pitävät virheellisinä. Tekoälyä päätöksentekoon käyttävien yritysten on siksi varmistettava, että niiden järjestelmät on suunniteltu antamaan selkeät ja ymmärrettävät selitykset siitä, miten päätökset tehdään, ja niiden on oltava valmiita perustelemaan tekemänsä päätökset (European Parliamentary Research Service, 2020).

3.4 Vinoumat

Bias koneoppimisessa viittaa algoritmien taipumukseen tehdä päätöksiä, jotka systemaattisesti suosivat tai syrjivät tiettyjä ihmisryhmiä tai tietotyyppisiä. Tämä vinouma voi johtua useista tekijöistä, mukaan lukien vinoutuneesta harjoitusdatasta tai virheellisistä algoritmeista (Norori et al, 2021).

Yleinen vinouman aiheuttaja koneoppimisessa on puolueellinen koulutusdata. Jos algoritmin kouluttamiseen käytetyt tiedot eivät edusta väestöä, jota se on tarkoitettu palvelemaan, tuloksena oleva algoritmi voi tehdä päätöksiä, jotka ovat puolueellisia tiettyjä ihmisryhmiä vastaan. Sydän- ja verisuonitautien ennustamiseen käytetyt ennustusmallit perustuvat pääosin miespainotteiseen tietoaaineistoon. Naisten sydän- ja verisuonitaudit ilmenevät eri tavalla tietoaaineistossa, kuin miesten, joten tämä voi johtaa siihen, että miespainotteiseen tietoaaineistoon perustuvat mallit eivät välttämättä ole yhtä tarkkoja tehdessään ennusteita naisille. Tämän voi määritellä datalähtöiseksi vinoumaksi (Norori et al., 2021). Inhimilliset ennakkoluulot voivat näkyä myös datassa, jota käytetään koneoppimisalgoritmien kouluttamiseen. Jos esimerkiksi aiemmin kerätyt tiedot sisältävät vääristymiä tiettyjä ihmisryhmiä kohtaan, algoritmit tekevät vinouman sisältäviä päätöksiä (Norori et al., 2021).

Algoritminen vinouma on ilmiö, joka tapahtuu, kun algoritmi tuottaa tuloksia, jotka ovat systemaattisesti ennakkoluuloisia virheellisten oletusten vuoksi. Jos algoritmi on koulutettu vinoutuneella tietoaaineistolla, se päättyy suosimaan useammin tilanteita, joissa ilmiö esiintyy datassa useammin. Obermeyerin ja muiden (2020) tutkimuksessa algoritmissa oli algoritminen- sekä dataan perustuva vinouma. Ongelma oli, että se käytti ennustemallia, joka nojautui terveydenhuollon kustannuksiin terveydenhuollon tarpeiden sijasta. Koska terveydenhuollon kustannuksissa on systemaattisia rodullisia eroja, malli päättyi aliarvioimaan tummaihoisten potilaiden tarpeita ja yliarvioimaan valkoisihoiden potilaiden tarpeita. Tämä johti siihen, että algoritmi suositteli tummaihoisille potilaille alhaisempaa hoitotasoa kuin valkoisihoiden potilaille, vaikka heillä olisi sama tarve. Tämä harha säilyi algoritmin käyttöönotossa, jossa terveydenhuollon työntekijät käyttivät sitä resurssien jakamiseen ja kliinisten päätösten tekemiseen (Obermeyer et al., 2020).

On tärkeää arvioida mahdollisuuksien tasoa objektiivisesti, jotta tuloksia ei tulkita väärin. Tätä varten voidaan käyttää esimerkiksi menetelmää, jossa otetaan saatavilla olevat näytteet ja sekoitetaan niiden tunnistetta satunnaisesti. Tämän jälkeen algoritmi koulutetaan uudelleen tuottamaan "satunnaisia" ennusteita, joiden avulla voidaan arvioida todennäköisyyksien tasoa. (Norori et al., 2021).

On myös tärkeää arvioida ja tarkastaa säännöllisesti koneoppimisjärjestelmiä, jotta voidaan havaita ja korjata ajan myötä mahdollisesti ilmeneviä vinoumia (Obermeyer et al., 2020). Nororin ja muiden (2021) artikkelissa peräänkuulutetaan tekoälyn reilua implementointia, jonka edellytyksenä on avoimuus ja kattavuus, jotka ovat osa avoimen tieteen toteutusta.

4 Yhteenveto

Tämän tutkielman tarkoituksena oli olla informatiivinen katsaus tekoälyn käyttöön päätöksenteossa ja selvittää sen käyttökohteita ja niihin kohdistuvia mahdollisia ongelmia. Tutkielma osoitti tekoälyn sovelluskohteita eri aloilla, sekä sen mahdollisia hyötyjä terveydenhuollon alalla. Tutkimustulos osoitti myös tekoälyn käytön tarjoamia etuja täsmälääketieteen alalla, kuten esimerkiksi John Hopkinsin PMAP:in tapauksessa ennustavassa arvioinnissa (Ravitz, 2021). Tutkielma tarjosi myös vastauksia siihen, millä tavoin tekoälyalgoritmeja voidaan kehittää eri koneoppimisen mallien avulla. En sisällyttänyt vahvistusoppimista tutkielmani toiseen lukuun, koska lähteeni eivät olleet painottuneet sen käsittelyyn.

Tutkielmassa vastattiin myös kysymykseen siitä, millaisia vaikutuksia datan ja algoritmien vinoumilla voi olla lopputuloksiin, joita ihmiset voivat käyttää päätöksenteossa. Koneoppimisalgoritmeja kehittävien tai käyttävien henkilöiden tulisi huolehtia siitä, että koulutusdata on edustavaa ja puolueetonta, jotta vältettäisiin mahdolliset vinoumat. Lisäksi näiden henkilöiden tulisi käyttää algoritmeja, jotka on suunniteltu ottamaan huomioon vinoumien mahdollisuus ja arvioida säännöllisesti koneoppimisjärjestelmien toimivuutta mahdollisten vinoumien havaitsemiseksi ja korjaamiseksi. (Norori et al., 2021; Obermeyer et al., 2020).

Tekoälyn käyttöä tarkasteltaessa esiin nousee tietoaineiston kautta asioita, joihin tulee kiinnittää huomiota, kuten datan hallintaan ja alueellisiin lainsäädäntöihin, kuten Euroopan Unionin asettama GDPR (European Parliamentary Research Service, 2020). Tutkielma ei pysty tarjoamaan täysin suoraa vastausta kysymykseen siitä, mitä datan omistajuudella ja hallinnalla tarkoitetaan, sillä se riippuu alasta ja siitä, kenet katsotaan datan omistajaksi missäkin tilanteessa (Fadler & Legner, 2020). Datan keräämistä saattaa myös monimutkaistaa se, että useilla alueilla on erilaiset säädökset datan käyttöön ja yksityisyyteen (Scassa, 2018).

Käytännön sovelluksien mahdollisten hyötyjen ja toiminnallisuuksien lisäksi on tärkeää mainita Nororin ja muiden (2021) artikkelin esiin tuomia ongelmakohtia algoritmisen ja tietoaineiston vinoumista, jotka voivat johtua erinäisistä syistä. Tutkimuksessa tuotiin esille myös mahdollisia ratkaisuja niiden ratkaisuun, esimerkiksi tietoaineiston laajentamista paremmin tosielämää edustavaksi lisäämällä vähemmän datassa näkyviä ryhmien tietopisteitä tietoaineistoon. Kovin laajaa vastausta tutkielmakysymyksen moninaiisiin aiheisiin tämän tutkielman puitteissa ei kuitenkaan voi tarjota ja jatkotutkimusaiheina voisikin olla algoritmien kehitys ja datan omistajuuteen ja hallintaan liittyvät yksityiskohdat eri aloilla.

On olemassa useita erilaisia tekoälyalgoritmeja, joita käytetään yleisesti päätöksenteossa. Yksi suosituimmista on koneoppiminen, jossa tietokone opetetaan tunnistamaan datan kuvioita. Tämän tyyppistä algoritmia voidaan käyttää monenlaisiin sovelluksiin, kuten kuvantunnistamiseen (Lakhani et al., 2018). Toinen tärkeä tekoälyalgoritmityyppi on syväoppiminen, joka on koneoppimisen osajoukko, joka käyttää hermoverkkoja datan analysointiin (Aggrawal, 2018, s.106).

Algoritmit ovat yhtä hyviä kuin ne tiedot, joita niille syötetään ja jos kyseiset tiedot ovat vääristyneitä tai puutteellisia, algoritmin tulos on myös vääristynyt. Ihmiset ovat paremmin varustettuja tunnistamaan ja korjaamaan vääristymiä sekä voivat tuoda laajemman valikoiman näkökulmia ja kokemuksia päätöksentekoprosessiin. Ne eivät kykene empatiaan, myötätuntoon tai ymmärtämään inhimillisiä tunteita. Nämä ominaisuudet ovat olennaisia aloilla kuten terveydenhuolto, jossa yksilöiden hyvinvointi ja menestys riippuvat inhimillisestä yhteydestä ja ymmärryksestä. Tämän vuoksi käytössä olevia tekoälyalgoritmeja tulee kehittää, valvoa ja arvioida, jotta voidaan varmistua siitä, että ne rakentuvat tarpeeksi edustavalle ja oikeelliselle datalle ja algoritmiselle perustalle.

Lähdeluettelo

1. Aggrawal, C.C. (2018). *Neural Networks and Deep Learning – A Textbook*. Viitattu 6.4.2023. eBook. Springer International Publishing AG. ISBN 978-3-319-94463-0.
2. Asswad, J. & Gómez, J.M. (2021). *Data Ownership: A Survey*. Viitattu 5.4.2023. *Information* 2021, 12(11), 465; <https://doi.org/10.3390/info12110465>
3. Babylon Health. n.d. *AI*. Verkkosivu. Viitattu 19.3.2023. <https://www.babylon-health.com/en-gb/ai/>
4. Bates, A. (n.d). *Why AI will soon be indispensable for pharma sales teams*. Verkkosivu. Viitattu 20.3.2023. <https://eularis.com/why-ai-will-soon-be-indispensable-for-pharma-sales-teams/>
5. Butryn, B., Chomiak-Orsa, I., Hauke, K., Pondel, M., & Siennicka, A. (2021). *Application of Machine Learning in medical data analysis illustrated with an example of association rules*. *Procedia Computer Science*, 192, 3134–3143. <https://doi.org/10.1016/j.procs.2021.09.086>
6. Chandramouli, S., Dutt, S., & Das, A. (2018). *Machine Learning*. Viitattu 19.3.2023. Ensimmäinen painos. Pearson Education India. ISBN: 93-89588-13-8.
7. European Parliament. (2020). *Ethics of artificial intelligence*. Viitattu 19.4.2023. [https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641530/EPRS_STU\(2020\)641530_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641530/EPRS_STU(2020)641530_EN.pdf)
8. Fadler, M. & Legner, C. (2020). *Data ownership revisited: clarifying data accountabilities in times of big data and analytics*. *Journal of Business Analytics*. Vol 5:1. <https://doi.org/10.1080/2573234X.2021.1945961>
9. Faraj Al-Janabi, S. T. & Saeed, H. A. (2011). *A neural Network Based Anomaly Intrusion Detection System*. 4th International Conference on Developments in eSystems Engineering, DeSE 2011, (December 2011), pp. 221– 226. doi: 10.1109/DeSE.2011.19.
10. Gilbert, S., Mehl, A., Baluch, A., Cawley, C., Challiner, J., Fraser, H., Millen, E., Montazeri, M., Multmeier, J., Pick, F., Richter, C., Türk, E., Upadhyay, S., Virani, V., Vona, N., Wicks, P., & Novorol, C. (2020). *How accurate are digital*

- symptom assessment apps for suggesting conditions and urgency advice? A clinical vignettes comparison to GPs. *BMJ open*, 10(12).
<https://doi.org/10.1136/bmjopen-2020-040269>
11. HUS. (2020). Koronabotti. Viitattu 29.2.2023. <https://koronabotti.hus.fi/>
 12. Jain, A.K. & Dubes, R. D. (1988). *Algorithms for Clustering Data*. Prentice Hall, New Jersey, USA. ISBN: 0-13-022278-X.
 13. Kela. (2022). Automaattiset päätökset. Viitattu 29.2.2023. Osoite: <https://www.kela.fi/automaattiset-paatokset>
 14. Lakhani, P., Gray, D.L., Pett, C.R, Nagy, P. & Shih, G. (2018). Hello World Deep Learning in Medical Imaging. *J Digit Imaging*. Vol. 31. 283–289.
<https://doi.org/10.1007/s10278-018-0079-6>
 15. Na, S., Xumin, L. & Yong, G. (2019). Research on k-means Clustering Algorithm An Improved k-means Clustering Algorithm. 2010 Third International Symposium on Intelligent Information Technology and Security Informatics, Jian, Kiina. pp. 63-67. DOI: 10.1109/IITSI.2010.74
 16. Norori, N., Hu, Q. Aelle, F.M., Faraci, F. D. & Tzovara, A. (2021). Addressing bias in big data and AI for health care: A call for open science. Vol. 2:10. 100347. doi.org/10.1016/j.patter.2021.100347
 17. Obermeyer, Z., Powers, B., Vogeli, C. & Mullainathan, S. (2019) Dissecting racial bias in an algorithm used to manage the health of populations. *Science*. Vol366:6464. S.447–453. doi.org/10.1126/science.aax2342.
 18. Rawat, R., & Yadav, R. (2021). Big Data: Big Data Analysis, Issues and Challenges and Technologies. IOP Conference Series: Materials Science and Engineering, Volume 1022. 1st International Conference on Computational Research and Data Analytics (ICCRDA 2020) 24.10.2020, Rajpura, Intia.
<https://doi.org/10.1088/1757-899X/1022/1/012014>
 19. Ravitz, A.D. (2021). Big Data, Artificial Intelligence, and the Promise of Precision Medicine: A Johns Hopkins Collaboration to Develop the Precision Medicine Analytics Platform. *John Hopkins APL Technical Digest*. Vol. 25:4.
<https://secwww.jhuapl.edu/techdigest/Content/techdigest/pdf/V35-N04/35-04-Ravitz.pdf>
 20. Scassa, T., 2018. CIGI Papers No. 187 — September 2018 - Data Ownership - Teresa Scassa, Centre for International Governance Innovation. Canada. Retrieved from <https://canadacommons.ca/artifacts/2022549/cigi-papers-no/2774992/> on 23 Feb 2023. CID: 20.500.12592/nd7s0c.