

Aalto-yliopisto  
Perustieteiden korkeakoulu  
Teknistieteellinen kandidaattiohjelma

# **Tekoälyn hyödyntäminen sairauksien ehkäisyssä**

**Kandidaatintyö**

**23. huhtikuuta 2019**

**Viljami Raiski**

<b>Tekijä:</b>	Viljami Raiski
<b>Työn nimi:</b>	Tekoälyn hyödyntäminen sairauksien ehkäisyssä
<b>Päiväys:</b>	23. huhtikuuta 2019
<b>Sivumäärä:</b>	33
<b>Pääaine:</b>	Tietotekniikka
<b>Koodi:</b>	SCI3027
<b>Vastuopettaja:</b>	Professori Eero Hyvönen
<b>Työn ohjaaja(t):</b>	FT Sari Kujala (Tietotekniikan laitos)
<p>Digitalisaation lisääntyessä myös terveydenhuollon palveluissa on alettu soveltaa yhä enemmän tieto- ja viestintäteknologian eri sovelluksia. Yksi nykypäivän digitalisaatioon vahvasti liitetyistä käsitteistä on tekoäly ja sen eri sovellukset. Terveydenhuollossa tekoälyä voidaan potentiaalisesti hyödyntää monissa eri käyttökohteissa, kuten esimerkiksi sairauksien riskitekijöiden tunnistamisessa ja diagnosoinnissa.</p> <p>Työ on kirjallisuuskatsaus, jossa hyödynsin pääasiallisesti 2000-luvun kirjallisuusläheteitä aiheeseeni liittyen. Työssäni tarkastelen, mitä tekoälyn eri tekniikoita terveydenhuollon sovelluksissa käytetään ja miten näitä eri tekniikoita voidaan hyödyntää osana sairauksien ehkäisyä.</p> <p>Terveydenhuollon näkökulmasta merkityksellisiä tekoälyn tekniikoita ovat koneoppiminen ja luonnollisen kielen prosessointi. Koneoppimisen avulla voidaan analysoida sähköisten terveystietojen sisältämää strukturoitua dataa, esimerkiksi verenpainetta, painoa ja röntgenkuvia. Luonnollisen kielen prosessointia voidaan hyödyntää ei-strukturoidun datan käsittelyyn ja sitä kautta myös tuomaan esimerkiksi potilaskertomukset koneoppimisalgoritmeille ymmärrettävään muotoon. Tekoälyn eri sovelluksilla on monipuolisesti potentiaalisia käyttökohteita sairauden ehkäisyyn eri tasoilla. Tekoälyä on hyödynnetty esimerkiksi masennuksen ja melanooman tunnistamisessa sekä Alzheimerin taudin diagnosoinnissa ja ennustamisessa.</p> <p>Kokeellisissa olosuhteissa tekoäly on osoittanut potentiaalinsa sairauden ehkäisyyn tehostamisessa, mutta käytännön kokeiluja tarvitaan vielä lisää tulosten vahvistamiseksi. Käytännön hyödyntämisen esteinä voidaan nähdä esimerkiksi tiettyjen tekoälyn tekniikoiden vaikea ymmärrettävyys ihmisen näkökulmasta ja avoimet eettiset sekä lakitieteelliset kysymykset.</p>	
<b>Avainsanat:</b>	tekoäly, terveydenhuolto, sairauksien ehkäisy, koneoppiminen
<b>Kieli:</b>	Suomi

# Sisältö

<b>1 Johdanto</b>	<b>4</b>
<b>2 Tutkimusmenetelmät</b>	<b>6</b>
<b>3 Tekoälyn tekniikat terveydenhuollossa</b>	<b>7</b>
3.1 Tekoäly . . . . .	7
3.2 Koneoppiminen . . . . .	7
3.2.1 Lineaariregressio . . . . .	8
3.2.2 Logistinen regressio . . . . .	9
3.2.3 Tukivektorikone . . . . .	10
3.2.4 Neuroverkot . . . . .	11
3.2.5 Päättöpuu . . . . .	12
3.2.6 Satunnaismetsä . . . . .	12
3.2.7 Lähinaapurimenetelmät . . . . .	13
3.2.8 Naiivi Bayes - luokittelija . . . . .	13
3.2.9 Erotteluanalyysi . . . . .	14
3.2.10 Markovin piilomalli . . . . .	15
3.3 Luonnollisen kielen prosessointi . . . . .	15
3.4 Tekoälyn tulosten arviointi . . . . .	16
<b>4 Tekoälyn sovellukset sairauksien ehkäisyssä</b>	<b>18</b>
4.1 Primaarinen sairauksien ehkäisy . . . . .	18
4.2 Sekundaarinen sairauksien ehkäisy . . . . .	19
4.3 Tertiaarinen sairauksien ehkäisy . . . . .	22
<b>5 Johtopäätökset</b>	<b>25</b>
5.1 Tekoäly terveydenhuollossa . . . . .	25
5.2 Tekoälyn mahdollisuudet sairauksien ehkäisyssä . . . . .	26
5.3 Omia havaintoja työn onnistumisesta . . . . .	28
<b>Lähteet</b>	<b>29</b>

# 1 Johdanto

Teknologisen kehityksen seurauksena digitalisaatio on saavuttanut myös terveydenhuollon. Tieto- ja viestintäteknologiaa onkin alettu soveltaa niin terveydenhuollon palveluissa, prosesseissa kuin tuotteissa. Digitalisaatioon yksi vahvasti liitetystä osa-alueista on tekoälyn kehitys ja sen soveltaminen eri tarpeisiin. Terveydenhuollon sektorilla tekoälyn hyödyntäminen tarjoaa monipuolisesti mahdollisuuksia, sillä tekoälyn tekniikoita voidaan soveltaa suurten tietomäärien analysoinnissa, lääkäreiden apuna oikean hoidon valitsemisessa ja diagnoosi- ja hoitovirheiden vähentämisessä (Jiang et al., 2017). Tekoälyä on sovellettu terveydenhuollon kontekstissa niin diagnosoinnissa, potilaiden ohjeistamisessa kuin sairauksien riskitekijöiden tunnistamisessa (Nijeweme-d’Hollosy et al., 2018; Himes et al., 2009; Yeh et al., 2011; Barakat et al., 2010). Edellä mainitut sovelluskohteet ovat läheisesti yhteydessä sairauksien ehkäisyn eri vaiheisiin.

Sairauksien ehkäisyllä ja aikaisella puuttumisella on suuri vaikutus niin yksilöiden terveyden kuin julkisen talouden kustannusten näkökulmasta. Monien eri sairauksien, kuten esimerkiksi ihosyövän ja tyypin 2 diabeteksen tapauksissa aikaisella tunnistamisella ja väliintulolla voidaan vaikuttaa merkittävästi sairauden puhkeamiseen, mahdollisiin komplikaatioihin ja jopa potilaan elinajanodotteeseen (ASCO, 2016; Wu et al., 2014). Esimerkiksi tyypin 2 diabeteksen riskiä voidaan pienentää elämäntapamuutoksilla, kuten kävelyn lisäämisellä, jopa 60 % (Wu et al., 2014). Diabetesliiton mukaan diabetekseen liittyvät sairaanhoitokustannukset olivat Suomessa vuonna 2011 lähes 1,5 miljardia euroa (Koski et al., 2018), joten jo ainoastaan ehkäisemällä tyypin 2 diabetesta voitaisiin saavuttaa huomattavia taloudellisia säästöjä. Tekoälyn hyödyntäminen osana toimivaa sairauksien ehkäisyä voisi siten tehostaa nykyisen terveydenhuollon toimintaa, lisätä säästöjä ja parantaa lukuisten ihmisen elämänlaatua.

Tekoälyn soveltamiseen terveydenhuollon osana liittyy mahdollisuuksien lisäksi myös ongelmia ja avoimia kysymyksiä. Monet tekoälyn toteutuksessa käytetyt teknologiat, esimerkiksi neuroverkot, päätyvät järkevään ratkaisuun diagnosoidessaan tiettyä tautia, mutta eivät tarjoa lopputulokselleen ymmärrettäviä perusteluita (Lee et al., 2017). Sovellettaessa tekoälyä lääketieteellisiin tarkoituksiin tärkeäksi onkin muodostunut tekoälyn saaman lopputuloksen perustelu ihmisille ymmärrettävästi. Teknisten ongelmien lisäksi lain näkökulmasta oleellisia kysymyksiä on vastuun jakaminen: kenen vastuulla järjestelmän tekemät virheet ovat (Lee et al., 2017).

Tutkimuksellani pyrin löytämään vastaukset seuraaviin tutkimuskysymyksiin:

- Mitä tekoälyn eri tekniikoita hyödynnetään terveydenhuollossa ja miten ne toimivat?
- Miten tekoälyn eri tekniikoita voidaan hyödyntää sairauden ehkäisyn eri vaiheissa?

Ensimmäisellä tutkimuskysymykselläni haluan selvittää, mitkä tekoälyn eri tekniikat ovat relevantteja terveydenhuollon näkökulmasta, ja mitä nämä tekniikat yleisesti tarkoittavat ja miten ne toteutetaan. Toisella tutkimuskysymykselläni haluan selvittää, miten näitä eri tekniikoita on hyödynnetty sairauksien ehkäisyssä, miksi jokin tekniikka on valittu, mitkä olivat käytön tulokset sekä ilmenikö hyödyntämisen yhteydessä haasteita.

## 2 Tutkimusmenetelmät

Työ on toteutettu kokonaisuudessaan kirjallisuuskatsauksena, eikä se sisällä empiiristä tutkimusta. Kirjallisuuslähteitä kerättiin hyödyntäen eri tietokantoja, kuten Scopus ja Google Scholar. Tekoälyn kehitys ja tutkimus on ollut runsasta etenkin viime vuosina ja tekoälyn sovelluksia käsittelevistä tutkimuksista suurin osa valitsemistani olivatkin 2000-luvulla julkaistuja. Tekoälyn eri tekniikoista osa on kehitetty jo ennen 2000-lukua, joten tekniikoiden toteutuksesta kertovat valitsemani lähteet vaihtelevat huomattavasti julkaisuvuosiltaan.

Hakutermeinä käytettiin muiden muassa seuraavia aiheeseeni liittyviä hakutermejä ja niiden yhdistelmiä:

- health care, healthcare, eHealth, promotion, preventative healthcare,
- artificial intelligence, machine learning, artificial neural networks, natural language processing

Hakutuloksista keräsin otsikoiden perusteella artikkeleita, jotka vastasivat asettamiini tutkimuskysymyksiin. Kerätyistä artikkeleista suodatin tärkeimmät artikkelit lukemalla tutkimusten johdannon ja johtopäätökset. Johdannon ja johtopäätösten perusteella arvioin lähteen sopivuutta tutkimukseeni. Edellä mainittujen lisäksi arvioin tutkimuksia julkaisuvuoden perusteella ja huomioiden, kuinka usein kyseeseen tutkimukseen oli viitattu. Valittuani tutkimukseni kannalta oleelliset lähteet, luin ne läpi ja koostin lähteiden keskeisimmät löydökset muistiinpanoiksi. Kirjoitettujen muistiinpanojen pohjalta kokosin löydökseni yhtenäiseksi kandidaatintutkielmaksi.

## 3 Tekoälyn tekniikat terveydenhuollossa

Kirjallisuuskatsauksessaan Jiang et al. (2017) ehdottivat terveydenhuollon kontekstissa käytettäväksi tekoälyn tekniikoiksi kahta eri lähestymistapaa: koneoppiminen ja luonnollisen kielen prosessointi. Koneoppimista voidaan hyödyntää strukturoidun datan käsittelyssä. Strukturoituun dataan kuuluvat terveydenhuollon kontekstissa muun muassa eri kuvat, kuten magneetti- ja röntgenkuvat ja erilainen sähköisen diagnostiikan tuotama tieto. Luonnollisen kielen prosessointia voidaan puolestaan hyödyntää terveydenhuollon sovelluksissa ei-strukturoidun tiedon käsittelyyn. Terveydenhuollon ympäristössä ei-strukturoitua tietoa ovat muun muassa potilaskertomukset.

Tässä luvussa pyrin luomaan tarkemman kuvan siitä, mitä tekoäly on, mitä tekoälyn tekniikoita terveydenhuollon kontekstissa käytetään, miten nämä tekniikat toimivat ja mihin eri sovelluksiin tekniikoita voidaan hyödyntää.

### 3.1 Tekoäly

Tekoälyn tarkan ja kaiken kattavan määritelmän tuottaminen on hankalaa alan kehityessä jatkuvasti. Tekoälyn yhteydessä mainitaan usein sen ominaisuus jäljitellä ihmisen kognitiivisia ominaisuuksia (Jiang et al., 2017; Jha ja Topol, 2016) ja kyky tulkita ulkopuolista tietoa, oppia siitä ja mukautumalla saavuttaa määritellyt tavoitteet oppimaansa hyödyntäen (Kaplan ja Haenlein, 2019). Toisaalta kykyä jäljitellä ihmisen ajattelua on myös kritisoitu, sillä Patel et al. (2009) mukaan osa tekoälyn tutkijoista pitää tekoällyn perustuvan systeemin suorituskykyä tärkeämpänä kuin ihmismäistä ongelmien ratkomista. Osa tutkijoista puolestaan määrittelee tekoälyn tietotekniikan alahaaraksi, jossa keskitytään automatisoimaan älykästä käyttäytymistä (Luger, 2005).

### 3.2 Koneoppiminen

Shalev-Shwartz ja Ben-David (2014) määrittelevät koneoppimisen tietokoneen kykyä oppia autonomisesti syötetyn datan perusteella ja kyvyksi tunnistaa merkityksellisiä yhteyksiä datasta. Koneoppimista käytetään lukuisilla tieteenaloilla työkaluna, jolla suurista tietomääristä saadaan erotettua implisiittistä tietoa. Koneoppimisessa voidaan erottaa eri oppimisen tapoja ja yksi tapa erotella on jakaa ne ohjattuun ja ohjaamattomaan oppimiseen.

Ohjattu oppiminen voidaan nähdä prosessina, jossa tietokone opetetaan annetun datan perusteella tunnistamaan ja esimerkiksi luokittelemaan uutta tietoa (Shalev-Shwartz ja Ben-David, 2014). Esimerkiksi tietyn taudin tunnistamisen tapauksessa, tietokoneelle opetettaisiin ensin, mitkä eri oireet viittaavat kyseiseen tautiin. Opettamisen jälkeen

tietokone osaisi hyödyntää oppimaansa uusien potilaiden oireiden analysoinnissa. Ohjaamattomassa oppimisessa tilanne on toinen. Tietokoneen oppiminen tapahtuu ilman opetusdataa, eli tietokone käsittelee itsenäisesti sille annetun datan ja pyrkii järjestämään sen tietyllä tavalla tai tuottamaan yhteenvedon datasta. Terveystieteiden näkökulmasta ohjatulla oppimisella saadut tulokset ovat olleet toistaiseksi merkityksellisempiä kuin ohjaamattomalla oppimisella (Jiang et al., 2017). Ohjattua oppimista voidaan hyödyntää esimerkiksi diagnosoinnissa ja taudin etenemisen ennustamisessa. Ohjaamatonta oppimista on hyödynnetty puolestaan esimerkiksi terveydenhuollon datan esikäsitelyssä.

Kirjallisuuskatsauksessaan Jiang et al. (2017) kävivät läpi PubMed-tietokannan osalta lääketieteen tutkimuksia, joissa oli hyödynnetty eri koneoppimisen menetelmiä. Kymmenen eniten käytettyä tekniikkaa järjestettynä yleisyytensä perusteella olivat:

1. Tukivektorikone
2. Neuroverkot
3. Erotteluanalyysi
4. Logistinen regressio
5. Satunnaismetsä
6. Lineaariregressio
7. Naiivi Bayes -luokittelija
8. Lähinaapurimenetelmä
9. Päättöspuu
10. Markovin piilomalli

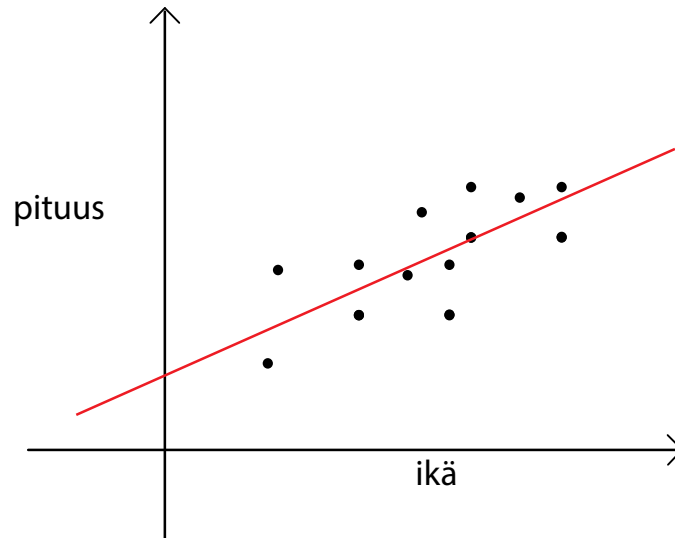
Tukivektorikone ja neuroverkot muodostavat enemmistön käytetyimmistä koneoppimisen menetelmistä, ja niitä on hyödynnetty yli puolissa kaikissa koneoppimiseen liittyvissä PubMed-tietokannan tutkimuksissa.

Seuraavissa osioissa tarkastelen tarkemmin yllämainittujen tekniikoiden toimintaperiaatteita ja sovellusalueita.

### 3.2.1 Lineaariregressio

Lineaariset ennustajat (engl. *linear predictors*) ovat paljon käytetty koneoppimisen muoto, jonka vahvuudet piilevät tehokkaassa oppimisessa, sopeutuvuudessa luonnollisen datan kanssa ja intuitiivisessa tulkittavuudessa (Shalev-Shwartz ja Ben-David, 2014). Yksi lineaarinen ennustamisen tapa on lineaarinen regressio (engl. *linear regression*), jossa pyritään mallintamaan yhteys selittävien muuttujien ja reaaliarvoisten tulosten kanssa (Russell ja Norvig, 2016). Tietokoneelle yritetään opettaa lineaarinen funktio, joka selittää parhaiten muuttujien välistä suhdetta. Mallin opettamiseen voidaan käyttää esimerkiksi pienimmän neliösumman estimaattia, jolla pyritään minimoimaan ero mallin lineaarisen funktion ja käsillä olevan datan välillä. Lineaarisen regression esimerkkisovellus voisi olla esimerkiksi pituuden ennustaminen iän perusteella (katso Kuva 1).






Kuva 1: Esimerkki lineaarisesta ennustajasta iän ja painon suhteen

### 3.2.2 Logistinen regressio


Toinen yleisesti käytetty lineaarisen ennustamisen muoto on logistinen regressio (engl. *logistic regression*) (Shalev-Shwartz ja Ben-David, 2014). Logistisessa regressiossa pyrkimyksenä on löytää funktioiden perhe, joiden avulla pyritään luokittelemaan uusi datapiste. Logististen funktioiden tuottaman arvo voidaan ajatella edustavan todennäköisyyttä sille, että datapiste luokitellaan tiettyyn luokkaan (Russell ja Norvig, 2016). Yleisesti logistisessa regressiossa käytetty funktio on S-kirjainta muistuttava Sigmoid-funktio (Shalev-Shwartz ja Ben-David, 2014). Sigmoid-funktio visualisoitu kuvassa 2. Logistisessa regressiossa virheen minimointiin ja mallin sovittamiseen voidaan hyödyntää esimerkiksi gradienttimenetelmää (engl. *gradient descent*) (Russell ja Norvig, 2016). Logistista regressiota voidaan hyödyntää esimerkiksi akuutin aivoverenvuodon ennustamisessa (Zhang et al., 2013).



Kuva 2: Esimerkki logistisesta Sigmoid-funktiosta. Y-akselin arvot vastaavat todennäköisyyksiä välillä 0-1.

### 3.2.3 Tukivektorikone

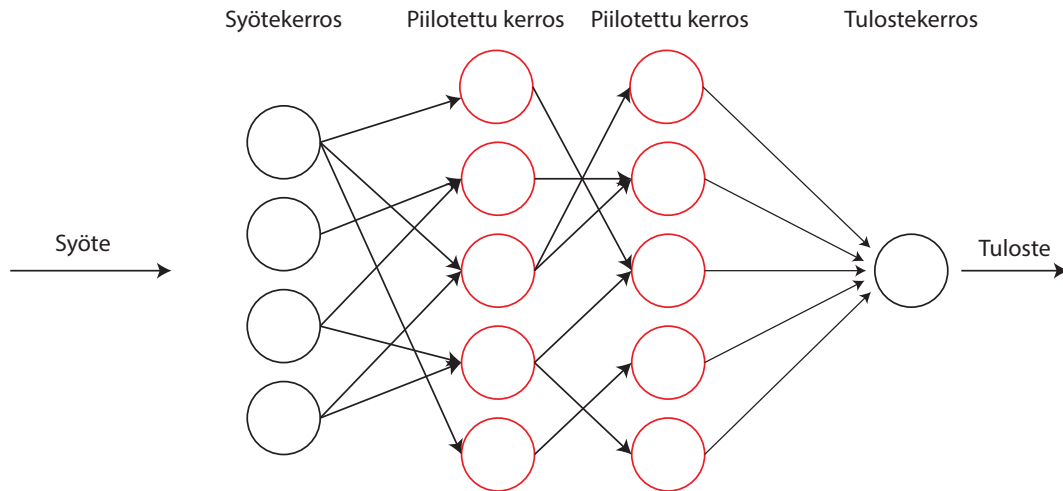
Tukivektorikone (engl. *support vector machine*) on lineaarinen oppimisen muoto, jossa pyritään tekemään lineaarista luokittelua tai regressiota moniulotteisessa piirreavaruudessa (Shalev-Shwartz ja Ben-David, 2014). Tavoitteena on muodostaa kahden näytejoukon väliin taso, joka jakaa näytteen kahteen luokkaan, siten että tason kanssa yhdensuuntaisten marginaalitasojen välinen etäisyys on mahdollisimman suuri eikä yksikään näyte ole marginaalitasojen välissä. Näytejoukon pisteet luokitellaan joko luokkaan +1 tai -1, marginaalitasoja rajoittavien tukivektoreiden perusteella (Bishop, 2006). Kuvassa 3 mustat pisteet on luokiteltu luokkaan -1 ja valkoiset pallot luokkaan +1. Käytännön sovelluksessa tämä luokittelu voisi edustaa esimerkiksi potilaiden jakoa syöpää sairastaviin ja terveisiin potilaisiin. Tukivektorikonetta onkin kokeiltu hyödyntää esimerkiksi rintasyövän tunnistamisessa (Sweilam et al., 2010).



Kuva 3: Havainnollistus tukivektorikoneen suorittamasta luokittelusta

### 3.2.4 Neuroverkot

Ajatus neuroverkoista (engl. *neural network*) on lähtöisin ihmisaivojen neuroverkkojen rakenteesta (Russell ja Norvig, 2016) . Yksinkertainen mallin mukaan ihmisaivojen voidaan ajatella muotoutuvan suuresta määrästä toisiinsa kytkeytyneistä neuroneista, jotka toimivat itsenäisesti laskennallisina yksikköinä. Neuroverkkojen toteutuksessa pyritään toteuttamaan aivojen yksinkertaisen mallin mukainen formaali laskennallinen rakenne keinotekoisesti. Neuroverkkojen rakennetta voidaan kuvata suunnattuna verkkona, jossa solmut esittävät aivojen neuroneja ja kaaret neuronien välisiä yhteyksiä (Shalev-Shwartz ja Ben-David, 2014). Yksi käytetyistä neuroverkkojen tyypeistä on myötäkytkentäneuroverkko (engl. *feedforward neural network*), jossa solmujen ja kaarien muodostamassa verkossa ei ole syklejä. Neuroverkossa jokaisen solmun syötteenä toimii painotettu summa siihen johtavien neuronien tulosteista. Neuroverkkojen rakennetta havainnollistaa Kuva 4. Neuroverkot voivat muodostua useammasta neuronien kerroksesta; syötekerros, piilotetut kerrokset ja tulostekerros, joka tuottaa neuroverkon antaman tuloksen. Neuroverkoissa voidaan hyödyntää monta eri neuronien kerrosta, jolloin useat kerrokset käsittelevät syötedataa. Tällöin neuroverkkoa kutsutaan syväksi neuroverkoksi (engl. *deep neural network*). Neuroverkkoja voidaan hyödyntää monipuolisesti terveydenhuollon sovelluksissa, esimerkiksi niin skitsofrenian kuin keuhkosityövän tunnistamisessa (Kim et al., 2015; Sun et al., 2016).



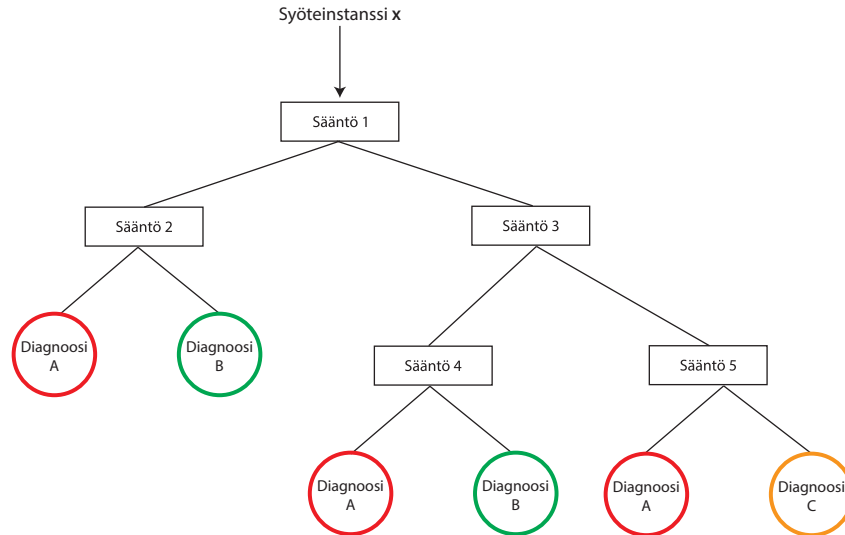
Kuva 4: Neuroverkkojen rakenne – syötekerros, yksi tai useampi piilotettu kerros ja tulostekerros

### 3.2.5 Päätöspuu

Päätöspuu (engl. *decision tree*) on ennustava malli, jolla pyritään ennustamaan annetulle syötteelle jokin ennalta määritetty luokka, kulkemalla muodostetun puurakenteen juuresta luokan sisältävään solmuun (Russell ja Norvig, 2016). Jokaisen solmun kohdalla on ehto, jonka perusteella ennustetaan, kumpaan alipuuhun syöte ohjataan uusien ehtojen käsiteltäväksi. Solmut käsittelevät niille annetun instanssin joko instanssin tietyn piirteen perusteella tai ennalta määritetyn jakamishdon mukaan. Esimerkki päätöspuusta Kuvassa 5. Päätöspuun syöteinstanssina voi olla esimerkiksi potilaan oireet, jolloin päätöspuu tuottaisi vastauksena oireita todennäköisimmin vastaavan diagnoosin. Kuva 5 havainnollistaa hyvin myös päätöspuun merkittävintä etua, se on helppo ja intuitiivinen ymmärtää. Päätöspuita on hyödynnetty esimerkiksi ihotautien tunnistamisessa yhdessä neuroverkkojen kanssa (Chang ja Chen, 2009).

### 3.2.6 Satunnaismetsä

Satunnaismetsä - algoritmi (engl. *random forest*) on luokittelija, joka hyödyntää kokoelmaa eri päätöspuita (Shalev-Shwartz ja Ben-David, 2014). Jokainen satunnaismetsä-algoritmissa hyödynnetty päätöspuu on tuotettu opetusdatasta, mutta erona on se, että päätöspuiden luonnissa piirteiden valintaan lisätään satunnaisuutta, valitsemalla lopulliseen päätöspuun malliin vaikuttavat piirteet satunnaisuutta hyödyntäen. Lopullinen luokittelu tapahtuu yksittäisten puiden enemmistön perusteella. Satunnaismetsä-algoritmin käyttö on yksi tapa välttää koneoppimisen mallin ylisovittuminen, joka tarkoittaa tilannetta, jossa tuotettu malli on sovitettu vastaamaan hyvin koulutusdataa mutta toimii huonosti uudella datalla eikä ole siten yleistettävissä. Satunnaismetsä-algoritmia on ko-



Kuva 5: Havainnollistus päätöspuun rakenteesta apuna diagnoosin tuottamisessa


keiltu soveltaa muun muassa itsetuhoisen käytöksen tunnistamisessa hyödyntäen sähköisiä terveystietoja (Carson et al., 2019).

### 3.2.7 Lähinaapurimenetelmät

Lähinaapurimenetelmä (engl. *nearest neighbour*) on algoritminen menetelmä, jossa tietokone pyrkii luokittelemaan uuden syöteinstanssin valmiiksi luokitellun harjoitusdatan perusteella (Shalev-Shwartz ja Ben-David, 2014). Syöteinstanssi luokitellaan sen lähimpien naapureiden luokkien mukaan. K-lähinaapurimenetelmässä (engl. *k-nearest neighbour*) uuden instanssin luokka päätetään naapurien lukumäärän perusteella, jonka määrää parametri  $k$ . Uuden instanssin luokaksi valitaan se luokka, joka on enemmistönä  $k$ -määrässä naapureita. Kuvassa 6,  $k$ -lähinaapurimenetelmää on sovellettu  $k$ :n arvolla neljä. Uusi instanssi luokitellaan luokkaan kaksi, sillä sen neljästä lähimmästä naapurista kolme kuuluu luokkaan kaksi. Lähinaapurimenetelmää on sovellettu muun muassa rintasyövän diagnoosinnissa (Osareh ja Shadgar, 2010).

### 3.2.8 Naiivi Bayes - luokittelija

Naiivi Bayes -luokittelija (engl. *Naive Bayes-classifier*) on esimerkki generatiivisesta koneoppimisen mallista, jossa oletetaan datalle jokin parametrein määritelty todennäköisyysjakauma (Shalev-Shwartz ja Ben-David, 2014). Tavoitteena on löytää dataa oletettavasti mallintavan jakauman parametrit ja hyödyntää mallia datan luokittelussa. Datajoukolle oletetun todennäköisyysjakauman parametrien estimointiin käytetään suurimman uskottavuuden estimaattia. Naive Bayes -luokittelijaa sovellettaessa oletetaan, että




Kuva 6: K-naapurimenetelmän soveltaminen  $k$ :n arvolla neljä

syötteen komponentit ovat toisistaan riippumattomia estimoinnin helpottamiseksi, vaikka tämä oletus ei pidäkään paikkaansa tosielämän sovelluksissa. Huolimatta siitä, ettei oletus toteudu tosielämässä, Naiivi Bayes -luokittelijat ovat osoittautuneet toimiviksi tosielämän sovelluksissa (Russell ja Norvig, 2016). Naiivi Bayes -luokittelijaa on sovellettu esimerkiksi sydäntautien tunnistamiseen (Vembandasamy et al., 2015).

### 3.2.9 Erotteluanalyysi

Erotteluanalyysin (engl. *discriminant analysis*) pohjimmaisena ideana on löytää tapa erotella käsillä oleva data kahteen tai useampaan luokkaan, ja hyödyntää tätä erottelua yksittäisen datapisteen erotteluun (Mardia et al., 1997). Erotteluanalyysissä luokittelu tapahtuu yksilön piirteiden perusteella. Esimerkkitilanteessa potilaan oireet vastaisivat piirteitä, ja nämä oireet pyritään yhdistämään tiettyyn tautiin. Erotteluanalyysiin liittyy eri lähestymistapoja riippuen siitä, kuinka paljon aikaisempaa tietoa datasta on saatavilla. Osassa lähestymistavoista, oletetaan tietyt todennäköisyysjakaumat olemassa oleville luokille, osassa puolestaan hyödynnetään saatavilla olevaa tietoa datajoukosta (Mardia et al., 1997). Erotteluanalyysillä on monia sovelluskohteita terveydenhuollossa ja esimerkiksi Armañanzas et al. (2013) hyödynsivät erotteluanalyysia Parkinsonin taudin vakavuuden arvioinnissa ei-motoristen oireiden perusteella. Erotteluanalyysin tuottamaa jakoa havainnollistaa Kuva 7, joka perustuu erotteluanalyysiin terveiden ja psykoottisten ihmisten välillä (Smith, 1947).



Kuva 7: Erottelumenetelmän soveltaminen terveiden ja psykoottisten ihmisten erotteluun (Smith, 1947).

### 3.2.10 Markovin piilomalli

Markovin piilomalli (engl. *hidden Markov model*) on koneoppimisessa hyödynnetty probabilistinen malli, jossa tietyn prosessin tilaa kuvaa vain yksi diskreetti satunnaismuuttuja (Russell ja Norvig, 2016). Markovin piilomalli eroaa perinteisestä Markovin mallista siten, että Markovin piilomallissa käsillä oleva stokastinen prosessi ei ole näkyvillä (Rabiner, 1989). Markovin piilomallia on yksi vähiten käytetyimmistä koneoppimisen malleista terveydenhuollon kontekstissa. Markovin piilomallia on kokeiltu hyödyntää esimerkiksi Huntingtonin tautiin tai aivoverenvuotoon liittyvän epänormaalien kävelytavan tunnistamisessa (Mannini et al., 2016).

## 3.3 Luonnollisen kielen prosessointi

Chowdhury (2003) määrittelee luonnollisen kielen prosessoinnin (engl. *natural language processing*) pyrkimykseksi ymmärtää ja muokata luonnollista tekstiä ja puhetta koneellisesti. Luonnollisen kielen prosessointia voi tapahtua eri tasoissa. Aluksi kieltä yritetään ymmärtämään yksittäisten sanojen tasolla. Seuraavaksi pyritään ymmärtämään yksittäisten sanojen muodostamia lauseita, niiden merkitystä ja kielioppia. Lopuksi pyritään ymmärtämään konteksti, johon lauseet sijoittuvat, sillä lauseiden ja sanojen merkitys voi muuttua kontekstista ja ympäristöstä riippuen. Luonnollisen kielen prosessoinnilla on paljon sovellusalueita osana terveydenhuoltoa. Suuri osa kliinisestä tiedosta on tekstimuo-

Oikea positiivinen Todellinen: pahanlaatuinen Koneen tulos: pahanlaatuinen <b>Määrä: 1</b>	Väärä positiivinen Todellinen: hyvälaatuinen Koneen tulos: pahanlaatuinen <b>Määrä: 1</b>
Väärä negatiivinen Todellinen: pahanlaatuinen Koneen tulos: hyvälaatuinen <b>Määrä: 8</b>	Oikea negatiivinen Todellinen: hyvälaatuinen Koneen tulos: hyvälaatuinen <b>Määrä: 90</b>

Taulukko 1: Hypoteettinen tilasto tekoälyn tunnistamista kasvaimista (Google, 2019a):

dossa, esimerkiksi potilaskertomukset, toimenpiteisiin liittyvät muistiinpanot ja laboratoriotulokset. Tietokone ei pysty käyttämään suoraan tätä strukturoimatonta tietoa, jonka vuoksi luonnollisen kielen prosessointi on tarpeen, jotta suurista datamääristä saadaan erotettua tietoa (Jiang et al., 2017). Luonnollisen kielen prosessointia on hyödynnetty esimerkiksi tunnistamaan leikkauksien jälkeisiä komplikaatioita, synnyännäisten sairauksien fenotyyppisiä ja aivoneurysmaa sähköisten potilaskertomusten perusteella (Murff et al., 2011; Karakülah et al., 2014; Castro et al., 2017).

### 3.4 Tekoälyn tulosten arviointi

Tekoälyn avulla saatuja tuloksia voidaan arvioida ja vertailla monella eri tavalla. Yksi yleisesti käytetty metriikka on täsmällisyyden (engl. *accuracy*) mittaaminen, joka kertoo, kuinka suuri osuus kaikista näytteistä luokiteltiin oikein (Google, 2019a). Täsmällisyyden lisäksi tulosten luotettavuutta voidaan arvioida tarkkuuden (engl. *precision*), herkkyyden (engl. *recall, sensitivity*) ja spesifisyyden (engl. *false positive rate, specificity*) avulla. Tarkkuus kertoo kuinka suuri osa positiivisista tuloksista oli todellisuudessa positiivisia (Google, 2019b). Herkkyydellä indikoidaan, kuinka monta positiivista näytettä tunnistettiin positiiviseksi (Google, 2019b). Spesifisyydellä tarkoitetaan väärin positiivisten osuutta kaikista negatiivista näytteistä (Google, 2019c).

Metriikkaa voidaan havainnollistaa esimerkiksi hypoteettisesta tilastosta tekoälyn luokittelemista kasvaimista. Taulukko 1 havainnollistaa hyvin eri metriikoiden eroja. Tekoälyn täsmällisyys tässä tapauksessa on 91 % (91 oikeaa luokittelua 100 näytteestä). Tarkkuus puolestaan on 50 % (yksi pahanlaatuinen kasvain tunnistettu oikein ja yksi hyvälaatuinen luokiteltu pahanlaatuiseksi). Herkkyydeksi saadaan taulukon arvoilla 11 % (pahanlaatuisia kasvaimia yhteensä yhdeksän, joista yksi luokiteltiin oikein). Spesifisyydeksi saadaan 99 % (90 hyvälaatuista kasvainta tunnistettu oikein 91 tapauksesta)



Esimerkin perusteella voidaan todeta, ettei yksi metriikka tuota täyttä vastausta tuotetun mallin luotettavuudesta, vaan luotettavuus on monen eri metriikan summa. Syöpäkasvaimen tunnistamisessa on siten perusteltua tarkastella erityisesti tarkkuutta, sillä pahanlaatuisen kasvaimen luokitteluun hyvälaatuiseksi vaarantaisi potilaan terveyden.

## 4 Tekoälyn sovellukset sairauksien ehkäisyssä

Edellisessä kappaleessa käsittelin yleisimpiä terveydenhuollon ympäristössä käytettyjä tekoälyn tekniikoita ja niiden toimintaperiaatteita. Seuraavassa luvussa käsittelen tarkemmin, miten eri lähestymistapoja voidaan hyödyntää osana sairauksien ehkäisyä. Käsittelen tekoälyn tekniikoiden sovelluksia sairauksien ehkäisyyn kolmella eri osa-alueella: primaarisen, sekundaarisen ja tertiaarisen sairauksien ehkäisyyn näkökulmista.

### 4.1 Primaarinen sairauksien ehkäisy

Primaarisessa sairauden ehkäisyssä pyritään vähentämään riskiä sairastua tiettyyn tautiin estämällä yksilön käyttäytymiseen tai ympäristöön liittyvien terveydelle haitallisten tekijöiden vaikutukset (Duodecim, 2018). Tekoälyn hyödyntämisen näkökulmasta mahdollisia sovelluskohtia ovat muiden muassa riskitekijöiden aikainen tunnistaminen käyttäytymis- ja ympäristötasolla.

Yksi tutkittu primaarisen sairauden ehkäisy näkökulma liittyy mielenterveyteen. Masennuksen riskitekijöiden aikainen tunnistaminen on tärkeää, sillä masennuksen on todettu lisäävän myös fyysisen sairastuvuuden riskiä. Esimerkiksi sepelvaltimotaudin riski on masentuneella henkilöllä 2–3-kertainen verrattuna muuhun väestöön (THL, 2015). Tutkimuksessaan De Choudhury et al. (2013) tutkivat tekoälyn hyödyntämistä masennuksen tunnistamisessa sosiaalisen median avulla. Tutkimukseen kerättiin Twitter-tilien dataa, joiden käyttäjät (N=476) olivat raportoineet saaneensa diagnoosin masennuksestaan. Tutkimuksen alkuvaiheessa erotettiin yhteiset piirteet masennusdiagnoosin saaneiden kesken. Yhteisiä piirteitä olivat esimerkiksi julkaisujen sanojen sisältö, aktiivisuus ja sosiaalisen median verkosto Twitter-palvelussa. Erotettujen piirteiden avulla koulutettiin tukivektorikone tunnistamaan henkilön Twitter-datan perusteella, oliko hänellä alttiutta masennukselle, ennen diagnosointia. Parhaimmillaan tutkijat saavuttivat 70 %:n täsmällisyyden ja 74 %:n tarkkuuden. Tutkimuksessa tuotettua luokittelijaa voitaisiinkin hyödyntää masennusriskin osoittamisessa ja automaattisen väliintulon mahdollistamiseen.

Ennakoivan terveydenhuollon näkökulmasta huomattava ongelma on myös syrjäytymisen, jolla tarkoitetaan yhteisöllisen toiminnan, esimerkiksi harrastus- ja yhteisötoiminnan, ulkopuolelle jäämistä (THL, 2018). Inhimillisen kärsimyksen lisäksi syrjäytyminen aiheuttaa merkittäviä taloudellisia kustannuksia. Pelkän peruskoulutuksen varaan jääneet aiheuttavat julkishallinnolle keskimäärin noin 250 000 – 370 000 euron tulonmenetyksen verrattuna koulutuksen saaviin (Hilli et al., 2017). Tekoälyn mahdollisuuksia syrjäytymisen ennakoinnissa tutkivat Talvitie-Lamberg et al. (2018). Tutkimuksessa hyödynnettiin valtakunnallista Terveyden ja hyvinvoinnin laitoksen teettämää 8–9-luokkalaisille suunnattua kouluterveyskyselyä. Kouluterveyskyselyn tuloksia analysoitiin ja arvioitiin

asiantuntija- ja tutkijaryhmän toimesta sekä hyödyntäen IBM:n SPSS Modeler-työkalua. Tutkimuksen tuloksena tuotettiin syrjäytymisriskiluokitus, sekä syrjäytymisriskikartta, jolla pystyttiin hahmottamaan syrjäytymisriskissä olevien oppilaiden lukumäärää alueittain. Riskiluokituksen ja riskikartan tuottamisen lisäksi aineistosta selvitettiin päätöspuumallilla, mitkä kouluterveyskyselyn kysymykset auttavat ennakoimaan parhaiten syrjäytymistä. Kymmenellä merkittävimmällä kysymyksellä saavutettiin 85 % todennäköisyydellä sama tulos kuin kaikkia 266 kysymystä hyödyntäen. Kymmenen tärkeintä kysymystä tarkastelivat muun muassa oman luokan työrauhaa, omaa ja vanhempien suhtautumista koulunkäyntiin ja terveyden ja hyvinvointiin liittyvää ammatillista tukea. Tutkimuksessa ei kuitenkaan tiedon anonyymiuden vuoksi saatu tuotettua syrjäytymistä ennustavia malleja, sillä todellisia henkilötietoja syrjäytymisriskissä olevista ei ole saatavilla. Tuotetun tekoälyratkaisun yhdeksi ongelmaksi mainitaan myös se, että datan ollessa anonyymia, ei tukitoimia voida kohdistaa yksittäisiin henkilöihin, vaikka riski tunnistettaisiin.

Primaarisen ehkäisyn näkökulmasta olennaista on tunnistaa sairauksien riskit aikaisessa vaiheessa. Chen et al. (2017) tutkivat, miten tekoälyn teknologioita voitaisiin hyödyntää aivoinfarktin riskiryhmään kuulumisen tunnistamisessa. Tutkimuksessa tarkasteltiin eri tekoälyteknologioiden soveltuvuutta strukturoidun ja ei-strukturoidun datan hyödyntämisessä. Tutkimuksessa hyödynnettiin sairaalan sähköisiä potilastietoja, kuvannuksia ja geenidataa kolmen vuoden ajalta. Kolmen vuoden aikana potilaita oli ollut lähes 32 000, joista lopulliseen tekoälyn koulutukseen käytettiin 706 potilaan tietoja. Tutkimuksen tuloksissa todettiin, ettei pelkästään strukturoituun dataan pureutuvat koneoppimisen menetelmät tuota riittävän luotettavaa ennustetta aivoinfarktin riskiryhmään kuulumisesta. Tutkimuksessa hyödynnettiin k-lähinaapurimenetelmää, päätöspuita ja Naivia Bayes-luokittelijaa strukturoidun datan käsittelyssä. Pelkästään strukturoitua dataa hyödyntämällä saavutettiin korkeimmillaan 63 %:n täsmällisyys. Tulos on huomattavasti heikompi kuin konvoluutioneuroverkolla saavutettu strukturoitua ja tekstidataa yhdistävä luokittelija, jolla saavutettiin 95 %:n täsmällisyys.

## 4.2 Sekundaarinen sairauksien ehkäisy

Sekundaarisessa ehkäisyssä tarkoituksena on ehkäistä aikaisessa, usein myös oireettomassa vaiheessa, olevaa tautia kehittymästä edelleen (Duodecim, 2018). Sekundaarisella ehkäisyllä saavutettu hyöty on siten suoraan yhteydessä sairauksien aikaiseen tunnistamiseen. Tekoälyä onkin hyödynnetty monien eri sairauksien, kuten ihosyövän, keuhkokuumeen ja diabeteksen tunnistamiseen ja riskin arvioimiseen (Esteva et al., 2017; Caruana et al., 2015; Wu et al., 2014; Roychowdhury et al., 2014).

Kuten monien muiden syöpien muotojen, myös ihosyövän tunnistamisessa aikaisella väliintulolla voidaan vaikuttaa suuresti potilaan selviämisen todennäköisyyteen. Mikäli pa-

hanlaatuinen ihosyöpä tunnistetaan sen ensimmäisessä vaiheessa ja hoito aloitetaan ajoissa, diagnoosin saaneen potilaan todennäköisyys olla hengissä vielä viiden vuoden päästä on 99 % (ASCO, 2016). Myöhäisessä vaiheessa tunnistettujen kasvainten kohdalla todennäköisyys selvitä voi laskea jopa 20 %:iin asti. Esteva et al. (2017) tutkivat, kuinka tekoälyä voitaisiin hyödyntää ihosyövän tunnistamisessa kuvien perusteella. Erotuksena aikaisempiin vastaaviin sovelluksiin, Esteva et al. (2017) halusivat tuottaa ratkaisun, jolla pystyttäisiin tunnistamaan pahanlaatuiset ihosyövät tavallisista valokuvista vaihtelevilla valotuksilla ja kuvakulmilla. Tutkijat päätyivät soveltamaan ratkaisussaan neuroverkkojen sovellutusta, syvää konvoluutioneuroverkkoa (*engl. deep convolutional neural network*). Koulutettuaan neuroverkon, he vertasivat neuroverkon diagnoosien täsmällisyyttä 21 ser-tifioidun ihotautilääkärien diagnoosien täsmällisyyteen. Luokitellessaan ihon yksittäisen leesiohyvälaatuiseen, pahanlaatuiseen ja ei-neoplastiseen leesion, Esteva et al. (2017) saavuttivat neuroverkollaan parhaimmillaan 72 %:n täsmällisyyden. Saavutettu tulos oli vertailukelpoinen dermatologistien täsmällisyyksiin, jotka olivat kahdessa eri iholääkärien ryhmissä 65,6 % ja 66 %. Tulos antoi siis näyttöä, että tekoälyn avulla on saavutettavissa iholääkärien tasoa vastaavia tarkkuuksia ihosyövän diagnosoinnissa. Esteva et al. (2017) ehdottavatkin, että tulevaisuudessa ihosyövän riskiä voitaisiin arvioida kustannustehokkaasti jopa puhelimella otettujen valokuvien perusteella. Tämä voisi heidän mukaansa lisätä myös ihosyöpien aikaisen vaiheen tunnistamista, sillä kynnyksen tarkempiin tutkimuksiin osallistumiseen laskisi, mikäli alustava diagnoosi olisi halpa ja helposti saatavilla.

Tyypin 2 diabeteksen komplikaatioista jopa 80 % on estettävissä tai siirrettävissä riskiryhmien tunnistamisen avulla (Barakat et al., 2010). Tutkimuksessaan Barakat et al. (2010) tarkastelivat, kuinka tekoälyn voisi valjastaa osaksi tyypin 2 diabeteksen tunnistamista. Tutkijoiden tuottama malli oli tukivektorikone, jonka avulla pystyttiin ennustamaan diabetesta 94 %:n täsmällisyydellä, 93 %:n herkkyydellä ja 94 %:n spesifisyydellä. Tilastollisesta luotettavuudesta huolimatta, tutkijoiden kehittämä malli sisälsi kuitenkin yhden ongelmakohdan. Tukivektorikoneen avulla saatiin tuotettua lopullinen luokittelu diabetesta sairastavan ja terveen henkilön välillä, mutta ei perusteluja luokittelulle. Lääketieteen sovellusten kannalta perusteluilla on suuri merkitys mallin luottamuksen kannalta, sillä ilman perusteluja luokittelun oikeellisuutta on vaikea todentaa. Tämän ratkaisemiseksi tutkijat kehittivät mallin, joka tuotti myös perustelut ratkaisun tueksi. Kehitetystä tukivektorikoneesta saatiin erotettua muun muassa seuraava sääntöjoukko:

- JOS paastoverensokeri  $> 106,2$ : potilaalla diabetes
- JOS vyötärön ympäryys  $\geq 91$  ja diastolinen verenpaine  $\geq 90$ : potilaalla diabetes
- Oletus: ei diabetesta

Tuotetun sääntöjoukon raja-arvoja verensokerin, vyötärön ympäryksen ja diastolisen ve-

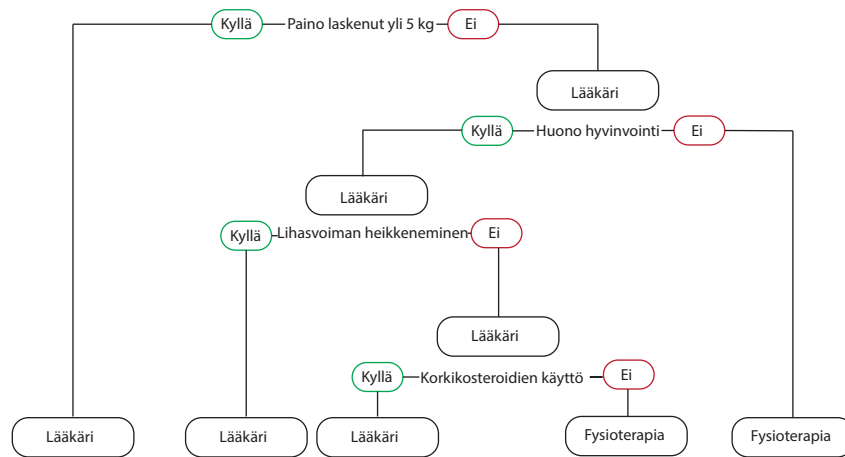
renpaineen osalta verrattiin lääketieteellisiin viitearvoihin, jotka tukivat tulosten oikeellisuutta.

Yksi tapa toteuttaa sekundaarista sairauksien ehkäisyä on pyrkiä ohjaamaan potilaita oikeaan hoitoon mahdollisimman nopeasti. Tekoälyä tähän tarkoitukseen hyödynsivät Nijeweme-d’Hollosy et al. (2018) tutkiessaan, kuinka koneoppimisen malleja voitaisiin soveltaa alaselän kipujen hoidon tarpeen arvioinnissa. Alaselkäkipujen jatkuessa pitkään, riski vaivan kroonistumiseen kasvaa. Kroonistuessaan selkäkivut voivat aiheuttaa esimerkiksi työkyvyttömyyttä ja sitä kautta huomattavia yhteiskunnallisia kustannuksia. Tutkimuksessaan Nijeweme-d’Hollosy et al. (2018) käyttivät kolmea eri koneoppimisen muotoa; päätöspuita, tehostettu puu (engl. *boosted tree*)- ja satunnaismetsä-algoritmeja. Opettamiseen hyödynnettiin 1288 fiktiivistä potilaskertomusta ja testaamiseen 38 tosielämän tapausta. Lopputuloksena saatiin seuraavat tarkkuudet:

Algoritmi	Täsmällisyys (opetusdata)	Täsmällisyys (testidata)
Päätöspuu	71 %	70 %
Satunnaismetsä	69 %	53 %
Tehostettu puu	72 %	71 %

Tuotetun mallin tarkkuus oli siis korkea ja kokonaisuudessaan tutkimus antoi lupaavia tuloksia tekoälyn mahdollisuuksista potilaan päätöksentekoa tukevana palveluna. Huolimatta tutkimuksen korkeasta tarkkuudesta, täytyy tutkimuksessa saavutettuja tuloksia tarkastella kriittisesti. Mallin koulutukseen käytetty data oli epätasaisesti jakautunutta sillä vain pienelle osalle (2 %) potilaista oli ohjeistettu oireiden hoitaminen omatoimisesti ja loput potilaat ohjattiin joko lääkärin tai fysioterapeutin vastaanotolle. Lopputuloksena oli malli, joka tunnisti tarkasti lääkärin tai fysioterapeutin vastaanottoa vaativat vaivat, mutta ei lainkaan omahoidolla hoidettavia vaivoja. Tuotettu päätöspuun malli visualisoitu Kuvassa 8. Tulevaisuudessa kliinisen hoidon arvioinnin malleja kehitettäessä voitaisiinkin pyrkiä keräämään dataa kattavasti kaikista kolmesta eri tapauksesta.

Potilasvirran hallintajärjestelmien osalta vastaavaa ratkaisua tutkivat Tenhunen et al. (2018) osana Myyrmäen terveyskeskuksen toimintaa. Tutkimuksessa havaittiin, että jo viiden kuukauden kokeilun aikana kyettiin saavuttamaan taloudellisia säästöjä. Viiden kuukauden tarkastelujakson aikana saavutettiin 31 euron säästö potilasta kohden, joka vastasi noin 14 % kustannusten laskua normaaliin kuukauteen verrattuna. Taloudellisten tulosten lisäksi tutkimusjakson aikana raportoitiin henkilökunnan tehokkuuden parantuneen, kun aikaa ei kulunut tarpeellisen hoidon arviointiin.



Kuva 8: Nijeweme-d’Hollosey et al. (2018) tuottama päätöspuu potilaiden päätöksenteon avustamiseksi alaselkäkivun perusteella. Päätöspuun eri sääntöjen perusteella potilaat ohjattiin joko lääkärin tai fysioterapeutin vastaanotolle.

### 4.3 Tertiaarinen sairauksien ehkäisy

Tertiaarisessa sairauden ehkäisyssä tarkoituksena on pyrkiä torjumaan sairauden eteneminen, taudista aiheutuvien haittojen paheneminen ja komplikaatioiden syntyminen (Duodecim, 2018). Esimerkkejä tertiaarisesta ehkäisyä ovat esimerkiksi kuntoutus ja sydäninfarktipotilaan uuden infarktin estäminen.

Sairauksien komplikaatioiden tunnistamisen ja ehkäisyn näkökulmasta tekoälyn hyödyntämistä tarkastelivat Roychowdhury et al. (2014). Tutkimuksessaan Roychowdhury et al. (2014) esittelivät tietokoneavusteisen seulontajärjestelmän diabeteksen aiheuttaman verkkokalvon sairauden, diabeettisen retinopatian, tunnistamiseen. Tutkijoiden ehdottama järjestelmä hyödynsi seulonnassaan silmänpohjakuvia. Pahimmillaan retinopatia voi aiheuttaa vakavan näkövamma, joka on ehkäistävissä oikein ajoitetulla ja laadukkaalla hoidolla (Tarnanen et al., 2017). Tutkimuksessa hyödynnettiin neljää eri koneoppimiseen perustuvaa luokittelijaa, Gaussian Mixture - malli, tukivektorikone, lähinaapurimenetelmä ja Adaboost. Neljä eri luokittelijan mallia koulutettiin kahdella eri datajoukolla. Toisen sisälsi 89 kuvaa, joista oli manuaalisesti luokiteltu silmänpohjan eri leesioita, ja toinen sisälsi 1200 kuvaa, jotka oli manuaalisesti luokiteltu eri vakavuusasteisiin. Tutkimuksessa tuotettu järjestelmä oli sekä luotettava että tehokas. Kolmivaiheinen järjestelmä kykeni tunnistamaan diabeettisen retinopatian ja sen vakavuuden parhaimmillaan 100 % herkkyydellä ja 53% spesifisyydellä hyödyntämällä Gaussian Mixture -luokittelijaa. Luotettavuuden lisäksi tutkimuksessa saavutettiin tehokkuuden näkökulmasta lupaavia tuloksia, sillä järjestelmä antoi vastauksen noin kuudessa sekunnissa. Tutkimuksen heikkoutena voidaan mainita epätasaisesti jakautunut data, joka ei sisältänyt tasaista määrää eri vakavuusasteita ja eri leesioita. Tämä datan epätasaisuus vaikutti tutkijoiden mukaan

	TK vs. AT	TK vs. eaKH	TK vs. aKH
Täsmällisyys	96 %	59 %	79 %

Taulukko 2: Saavutetut tarkkuudet (Salvatore ja Castiglioni, 2018)

	AT vs. aKH	AT vs. eaKH	eaKH vs. aKH
Täsmällisyys	78 %	90 %	62 %

Taulukko 3: Saavutetut tarkkuudet (Salvatore ja Castiglioni, 2018)

heikentävästi tukivektorikoneen luotettavuuteen.

Tertiaarisen ehkäisyn kohdistuessa jo sairastuneisiin, olennainen osa sitä on myös sairauden hillitseminen ja etenemisen hidastaminen. Yksi tähän kategoriaan kuuluvista toimenpiteistä on Alzheimerin taudin hoitaminen. Alzheimerin tauti on aivoja rappeuttava muistisairaus, ja se yleistyy voimakkaasti iän lisääntyessä (Juva, 2018). Alzheimerin tautiin ei ole olemassa sairauden pysäyttävää hoitoa mutta lääkehoidolla taudin etenemistä voidaan hidastaa. Alzheimerin taudin tunnistamista ja ennustamista tutkivat Salvatore ja Castiglioni (2018). Tutkimuksessa hyödynnettiin Alzheimer’s Disease Neuroimaging Initiative - datajoukkoa, joista valittiin 240 valmiiksi luokiteltua magneettikuvaa tekoälyn kouluttamiseen. Magneettikuvat oli luokiteltu neljään luokkaan, Alzheimerin tautia sairastavat (AT), terveet kontrollipotilaat (TK), Alzheimerin taudiksi edenneet kognitiiviset heikentymät (aKH), ja kognitiiviset heikentymät, jotka eivät kehittyneet Alzheimerin tautiin asti (eaKH). Luokiteltujen magneettikuvien avulla tutkijat kouluttivat tukivektorikoneen tunnistamaan eri luokkaan kuuluvia magneettikuvia.

Tutkimuksessa saavutetut täsmällisyydet on esitetty taulukoissa 2 ja 3. Tutkimuksessa saavutettu 96 % täsmällisyys terveen kontrollipotilaan ja Alzheimerin tautia sairastavan luokittelussa antaa lupaavia tuloksia tekoälyn kyvystä toimia Alzheimerin taudin diagnosoinnin apuna. Alzheimerin taudin ennakoinnin kannalta oleellinen tulos oli 79 % täsmällisyys luokittelussa terveen potilaan ja Alzheimerin taudiksi etenevän kognitiivisen heikkenemän välillä. Taulukoissa 2 ja 3 saavutetut tarkkuudet pätevät vain luokittelussa kahden eri luokan välillä. Salvatore ja Castiglioni (2018) yhdistivät koulutetut luokittelijat yhdeksi luokittelijaksi, jolla he pyrkivät luokittelemaan magneettikuvan johonkin neljästä edellä mainitusta luokasta. Tässä käyttötapauksessa saavutettu täsmällisyys oli 57 %, joka oli huomattavasti matalampi kuin tarkkuus Alzheimerin tautia sairastavan ja terveen potilaan välillä. Huolimatta verrattain matalasta tarkkuudesta, tutkijoiden tuottama luokittelija oli kuitenkin satunnaista arvaamista parempi.

Komplikaatioiden ehkäisyn lisäksi tekoälyn mahdollisuuksia on sovellettu myös kuntoutuksen näkökulmasta. Tuki- ja liikuntaelinsairauksien kuntoutuksessa tärkeä vaikuttava tekijä on fysioterapia ja sen toteuttaminen käytännössä. Burns et al. (2018) tutki-

vat, kuinka kotona tehtyjä harjoitteita voitaisiin monitoroida hyödyntämällä kaupallisten älykellojen keräämää dataa. Tutkimuksessa vertailtiin neljää eri koneoppimisalgoritmia; satunnaismetsä-algoritmia, lähinaapurimenetelmää, tukivektorikonetta ja takaisinkytkettyä konvoluutioneuroverkkoa. Näillä neljällä eri menetelmällä pyrittiin tunnistamaan seitsemän eri olkapäätä harjoittavaa liikettä älykellon sensorin datan perusteella. Burns et al. (2018) saavuttivat kaikilla tekniikoilla yli 80 % täsmällisyyden uuden datan luokittelussa ja parhaaksi menetelmäksi osoittautui konvoluutioneuroverkko, jolla saavutettiin 88,9 %:n täsmällisyys. Tuotetun mallin soveltuvuutta yleiseen käyttöön heikentää kuitenkin, se että tutkimuksessa seurattiin ainoastaan pienen joukon ( $N = 20$ ) tuottamaa dataa fyysisten harjoitteiden suorittamisesta. Lisäksi kaikki osallistujat olivat terveitä eikä yksikään osallistujista ollut läpikäynyt olkapään leikkausta. On luonnollista olettaa, että olkapäälleikkauksen läpikäynyt potilas suorittaa fyysiset harjoitteet eroavat liikeraodoiltaan terveiden potilaiden liikeradoista. Tutkimuksen tuloksena saavutettu tarkkuus antoi kuitenkin perusteita sille, että tekoälyä voitaisiin tulevaisuudessa hyödyntää myös osana fysioterapiaa ja fyysisten harjoitteiden monitorointia.



## 5 Johtopäätökset

Kirjallisuuskatsaukseni tavoitteena oli tutkia, mitä ja millaisia tekoälyn tekniikoita terveydenhuollon alalla on hyödynnetty ja miten näitä tekniikoita voitaisiin hyödyntää sairauksien ehkäisyssä eri vaiheissa.

Tässä luvussa kootaan yhteen löytämiäni tuloksia, joiden lisäksi esittelen omia ja kirjallisuudessa esitettyjä ajatuksia tekoälyn soveltamisesta sairauksien ehkäisyssä, potentiaalista hyödyistä ja mahdollisista ongelmista. Lopuksi arvioin opinnäytetyöhön liittyvän tutkimuksen onnistuneisuutta ja laajuutta.

### 5.1 Tekoäly terveydenhuollossa

Kirjallisuuskatsaukseni ensimmäinen tutkimuskysymys koski tekoälyn eri tekniikoita ja miten ne on toteutettu. Tekoälyä onkin sovellettu monipuolisesti monissa eri tarkoituksissa ja monilla eri tekniikoilla. Terveydenhuollon kannalta erityisen relevanteiksi tekoälyn tekniikoiksi ovat osoittautuneet koneoppiminen ja luonnollisen kielen prosessointi. Koneoppimisen osalta erityisesti ohjattuun oppimiseen perustuvat menetelmät ovat osoittautuneet relevanteiksi terveydenhuollon näkökulmasta, sillä niitä on hyödynnetty onnistuneesti esimerkiksi sairauksien diagnosoinnissa ja ennustamisessa.

Koneoppimisen eri algoritmeja voidaan hyödyntää strukturoidun datan, esimerkiksi verenpaineen, painon ja verensokerin arvojen analysointiin. Luonnollisen kielen prosessointia voidaan puolestaan hyödyntää strukturoimattoman datan, esimerkiksi lääkärin muistiinpanojen, analysointiin. Terveydenhuollon näkökulmasta molempien tekniikoiden yhtäaikainen hyödyntäminen on erityisen tärkeää luotettavien mallien tuottamiseksi, sillä iso osa terveydenhuollon datasta on kirjattuna ei-strukturoituna eli esimerkiksi tekstuaalisena datana potilaskertomuksissa. Luonnollisen kielen prosessoinnin avulla ei-strukturoitu data voidaan muokata koneoppimisalgoritmeille ymmärrettävään muotoon ja siten saavuttaa luotettavampia ennustamisen malleja.

Kaksi eniten käytettyä koneoppimisen menetelmää terveydenhuollon liittyvissä tutkimuksissa olivat tukivektorikone ja neuroverkot ja näitä tekniikoita hyödyntämällä on saavutettu lupaavia tuloksia niin eri syöpien, skitsofrenian kuin diabeteksen riskien tunnistamisessa. Huolimatta siitä, että merkittävä osa terveydenhuollon koneoppimissovelluksista hyödyntää jompaa kumpaa näistä kahdesta edellä mainitusta menetelmästä, eivät ne ole täysin ongelmattomia. Tukivektorikone ja neuroverkot edustavat koneoppimisen osalta malleja, jotka tuottavat vain vastauksen, esimerkiksi sairauden vakavuusasteen, mutta eivät perustelua vastauksilleen. Tämä voi osoittautua ongelmalliseksi käytännön sovellusten kannalta, sillä terveydenhuollon ammattilaiset useimmiten haluavat koneen tuottamalle vastaukselle lääketieteelliset perustelut. Tähän johtopäätökseen tulivat kirjallisuus-

katsauksessaan myös Ching et al. (2018). Tukivektorikoneen ja neuroverkkojen rinnalla on käytetty myös intuitiivisempia algoritmeja muun muassa päätöspuita ja päätöspuita hyödyntävää satunnaismetsä-algoritmia. Päätöspuita hyödyntävien ratkaisujen vahvuutena on helppo tulkittavuus ja lopputuloksen perusteluiden tarkistusmahdollisuus. Myös monet muut käytetyt algoritmit erottuvat edukseen intuitiivisuudellaan, esimerkiksi lähinaapurimenetelmä, jossa uuden datapisteen luokittelu tapahtuu datapisteen lähimpien naapurien luokkien enemmistön perusteella. Helpon ymmärrettävyyden ja perusteluiden tuottaminen ovat selvästi vahvuuksia, mutta usein näiden algoritmien avulla saavutettu luokittelun tarkkuus ei ole yhtä hyvä kuin esimerkiksi neuroverkoilla.

Koneoppimisen avulla saavutettuja tuloksia voidaan arvioida intuitiivisuuden lisäksi myös yleisesti käytetyillä metriikoilla, joita ovat esimerkiksi täsmällisyys, tarkkuus, herkkyys ja sensitiivisyys. Terveystenhuollon näkökulmasta on erityisen tärkeää tarkastella näitä lukuja kriittisesti ja kokonaisuutena, eikä vain luottaa yhden metriikan tuottamaan lukuun.

Kokonaisuudessaan tekoälyn eri tekniikoita voidaan hyödyntää monipuolisesti eri terveydenhuollon sovelluksissa ja sovelluksia suunnitellessa tulee huomioida monipuolisesti eri asioita, esimerkiksi, halutaanko optimoida järjestelmän ymmärrettävyyttä vai tarkkuutta.

## 5.2 Tekoälyn mahdollisuudet sairauksien ehkäisyssä

Tekoälyn soveltamista terveydenhuollon eri osa-alueilla on tutkittu laajasti, ja tutkimustulosten valossa tekoälyn eri sovelluksilla on potentiaalisia käyttökohteita sairauksien ehkäisyssä eri vaiheissa.

Primaarisessa sairauksien ehkäisyssä tekoälyä voitaisiin hyödyntää sairauksien, kuten masennuksen, aikaiseen tunnistamiseen. Lisäksi tekoälyä hyödyntämällä voidaan tunnistaa eri riskiryhmiin, esimerkiksi aivoinfarktin riskiryhmään, kuuluvia henkilöitä ja vaikuttaa aikaisella väliintulolla näiden riskin toteutumiseen. Primaarisen ehkäisyssä kannalta oleellista on myös tunnistaa sairastumisen riskiä lisäävät tekijät. Tästä näkökulmasta tarkasteltuna tekoälyn yksi sovelluskohta on syrjäytymisen aikainen tunnistaminen. Edellä mainittujen tekoälysovellusten avulla voitaisiin merkittävästi vaikuttaa sairauksien puhkeamiseen ja sitä kautta yhteiskunnallisiin kustannuksiin ja yksittäisten ihmisten elämänlaatuun.

Sekundaarisen sairauksien ehkäisyssä näkökulmasta tekoälyn sovellukset tuovat lisäarvoa oireettomassa tai aikaisessa vaiheessa olevan sairauden tunnistamisessa. Potentiaalia aikaisen vaiheen tunnistamisen osa-alueella on osoitettu niin ihosyövän kuin tyypin 2 diabeteksen aikaisessa tunnistamisessa. Lisäksi tekoälyä on kyetty hyödyntämään järjestelmässä, joka ohjaa potilaita oikeaan hoitoon oireiden perusteella. Monissa sairauksissa ennus-

tetta voidaan merkittävästä parantaa ja sairaudesta tulevaisuudessa aiheutuvia komplikaatioita välttää aikaisen tunnistamisen ja väliintulon avulla. Potilaiden ohjeistaminen oikean hoidon piiriin voi ehkäistä varhaisessa vaiheessa olevan sairauden pahenemista ja lisäksi tehostaa terveydenhuollon toimintaa ja sitä kautta vähentää sairauksien komplikaatioista johtuvia kokonaiskustannuksia.

Tertiaarisessa sairauksien ehkäisyssä tekoälyn hyödyntämiseen liittyneet sovellukset ovat osoittaneet potentiaalinsa myös sairauksista aiheutuvien komplikaatioiden tunnistamisessa ja osana kuntouttavaa toimintaa. Tekoälyn soveltuvuutta tertiaarisessa sairauksien ehkäisyssä puoltavat lupaavat tulokset diabeteksen komplikaation, diabeettisen retinopatian tunnistamisessa ja olkapäätä kuntouttavien liikuntaharjoitteiden tunnistamisessa. Osa tertiaarista sairauden ehkäisyä on myös taudin etenemisen hidastaminen. Lupaavia tuloksia on esitetty esimerkiksi Alzheimerin taudin ja sen vaiheiden tunnistamisesta. Alzheimerin taudin aikainen tunnistaminen ja sitä seuraava lääkityksen aloittaminen voivat hidastaa sairauden etenemistä ja siten parantaa sairastuneen henkilön elämänlaatua.

Tutkimuksissa saadut tulokset ovat kyenneet osoittamaan tekoälyn hyötyjen potentiaalın sairauksien ehkäisyssä kokeellisissa olosuhteissa. Kokeellisista olosuhteista on kuitenkin vielä matkaa käytännön sovelluksiin. Muutamia käytännön sovelluksia Suomessa ovat olleet tekoälyn hyödyntäminen keskoslasten verenmyrkytyksen tunnistamisessa ja potilaiden ohjeistamisessa oikeaan hoitoon oirearvion perusteella (Vierula, 2017; Tenhunen et al., 2018). Lisää tutkimuksia käytännön sovelluksista kuitenkin tarvitaan ennen kuin saadaan luotettavaa tietoa tekoälyn hyödyntämisestä osana sairauksien ehkäisyä.

Tekoälyn hyödyntämiseen terveydenhuollossa liittyy vielä paljon avoimia eettisiä ja lakitieteellisiä kysymyksiä. Eettisestä näkökulmasta mielenkiintoinen kysymys on: tulisiko meidän luottaa lääkäriä enemmän tekoölyyn, jos tekoälyn on todettu olevan tilastollisesti luotettavampi. Lakitieteellisestä näkökulmasta tarkasteltavia avoimia kysymyksiä liittyy paljon esimerkiksi vastuunjakoon virheellisen diagnoosin tapauksessa: kantaako tekoälyjärjestelmän tuottaja vai hoitopäätöksen tekijä vastuun virheellisen diagnoosin seurauksista.

Tekoälyä hyödyntämällä on saavutettu korkeita tarkkuuksia muun muassa eri tautien aikaisessa tunnistamisessa, mutta on tärkeä muistaa, etteivät tekoälyn järjestelmät kykene korvaamaan ihmistä potilastyössä. Tulosten perusteella voidaan perustellusti todeta, että tekoälyn eri järjestelmiä voitaisiin hyödyntää avustava työkaluna terveydenhuollon ammattilaisten apuna, ei korvaamaan ammattilaisia. Monet tekoälyn sovellukset, esimerkiksi kuvantunnistaminen, voisivat potentiaalisesti vähentää manuaalisen työn määrää ja siten tehostaa terveydenhuollon toimintaa ja sairauksien ehkäisyä.

### 5.3 Omia havaintoja työn onnistumisesta

Tutkimusmateriaalia tekoälyn hyödyntämisestä terveydenhuollon eri sovelluksissa on tutkittu runsaasti. Tekoälyn kehitys on viime vuosina ollut nopeaa ja jo 2000-luvun aikana on tapahtunut paljon muutoksia tutkimuksen suuntauksien osalta. Kirjallisuuskatsauksessa keskityinkin kattavasti 2000-luvun kirjallisuuteen. Kehityksen ollessa nopeaa, uusia ja parempia tutkimustuloksia saavutetaan nopeaan tahtiin. Tästä syystä monet lähempään tarkasteluun valitut tutkimukset ovatkin 2010-luvulta. Työhön liittyviä lähteitä oli helppo löytää ja vaikeuksia työssä tuottikin relevanttien lähteiden löytäminen suuresta määrästä tieteellistä tekstiä.

Huolimatta lähteiden paljoudesta, vain pieni osa lähteistä käsitteli suoraan tekoälyn hyödyntämistä sairauksien ehkäisyn eri vaiheissa. Tästä johtuen suoritin itse luokittelun tutkimustulosten mahdollisen soveltamisen suhteen. Lisäksi sairauksien ehkäisyn eri vaiheiden käsitteiden ollessa osittain päällekkäisiä, on tehtyä luokittelua syytä tarkastella kriittisesti, eikä pitää sitä ainoana oikeana jakona.

Työssäni käsittelin laajasti tekoälyn eri tekniikoita ja niiden sovelluksia sairauksien ehkäisyn eri vaiheissa. Työssäni pyrin luomaan kokonaiskuvan tekoälyn kannalta relevantista tekoälyn tekniikoista terveydenhuollossa ja niiden mahdollisista sovellusalueista sairauksien ehkäisyssä. Tulevissa tutkimuksissa olisi mielenkiintoista selvittää syvällisemmin tiettyjen tekniikoiden mahdollisuuksia terveydenhuollossa tai keskittyä esimerkiksi syvällisemmin tekoälyn hyödyntämiseen sekundaarisen ehkäisyn tasolla. Tulevissa tutkimuksissa olisi myös mielenkiintoista tutkia tekoälyn muiden osa-alueiden, kuten robotiikan ja päätöksenteon näkökulmaa sairauksien ehkäisyssä.

## Lähteet

- Ruben Armañanzas, Concha Bielza, Kallol Ray Chaudhuri, Pablo Martinez-Martin ja Pedro Larrañaga. Unveiling relevant non-motor parkinson's disease severity symptoms using a machine learning approach. *Artif. Intell. Med*, 58(3):195–202, 2013. doi: 10.1016/j.artmed.2013.04.002.
- ASCO. Melanoma: Statistics, 2016. URL <https://www.cancer.net/cancer-types/melanoma/statistics>. Viitattu 13.2.2019.
- Nahla Barakat, Andrew P. Bradley ja Mohamed Nabil H. Barakat. Intelligible support vector machines for diagnosis of diabetes mellitus. *IEEE Transactions on Information Technology in Biomedicine*, 14(4):1114–1120, jul 2010. doi: 10.1109/TITB.2009.2039485.
- Christopher M. Bishop. *Pattern recognition and machine learning*. Springer, 2006. ISBN 0-387-31073-8.
- David Burns, Nathan Eric Leung, Michael Hardisty, Cari M Whyne, Patrick Henry ja Stewart McLachlin. Shoulder physiotherapy exercise recognition: Machine learning the inertial signals from a smartwatch. *Physiological Measurement*, 39, 02 2018. doi: 10.1088/1361-6579/aacfd9.
- Nicholas J. Carson, Brian Mullin, Maria Jose Sanchez, Frederick Lu, Kelly Yang, Michelle Menezes ja Benjamin Lê Cook. Identification of suicidal behavior among psychiatrically hospitalized adolescents using natural language processing and machine learning of electronic health records. *PLOS ONE*, sivu 14, 2019. doi: <https://doi.org/10.1371/journal.pone.0211116>.
- Rich Caruana, Yin Lou, Johannes Gehrke, Paul Koch, Marc Sturm ja Noemie Elhadad. Intelligible models for healthcare: Predicting pneumonia risk and hospital 30-day readmission. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, osa 2015-August, sivut 1721–1730, 2015. doi: 10.1145/2783258.2788613.
- Victor M. Castro, Dmitriy Dligach, Sean Finan, Sheng Yu, Anil Can, Muhammad Abd-El-Barr, Vivian Gainer, Nancy A. Shadick, Shawn Murphy, Tianxi Cai et al. Large-scale identification of patients with cerebral aneurysms using natural language processing. *Neurology*, 88(2):164–168, 2017. doi: 10.1212/WNL.0000000000003490.
- Chun-Lang Chang ja Chih-Hao Chen. Applying decision tree and neural network to increase quality of dermatologic diagnosis. *Expert Systems with Applications*, 36(2): 4035–4041, 2009. doi: <https://doi.org/10.1016/j.eswa.2008.03.007>.

- Min Chen, Yixue Hao, Kai Hwang, Lu Wang ja Lin Wang. Disease prediction by machine learning over big data from healthcare communities. *IEEE Access*, 5:8869–8879, 2017. doi: 10.1109/ACCESS.2017.2694446.
- Travers Ching, Daniel S. Himmelstein, Brett K. Beaulieu-Jones, Alexandr A. Kalinin, Brian T. Do, Gregory P. Way, Enrico Ferrero, Paul-Michael Agapow, Michael Zietz, Michael M. Hoffman et al. Opportunities and obstacles for deep learning in biology and medicine. *Journal of The Royal Society Interface*, 15(141):20170387, 2018. doi: <http://dx.doi.org/10.1098/rsif.2017.0387>.
- Munmun De Choudhury, Michael Gamon, Scott Counts ja Eric Horvitz. Predicting depression via social media. *ICWSM*, 13:1–10, 2013.
- Gobinda G Chowdhury. Natural language processing. *Annual review of information science and technology*, 37(1):51–89, 2003. doi: 10.1002/aris.1440370103.
- Duodecim. *Lääketieteen sanasto*. Kustannus Oy Duodecim, 2018. URL <https://www.terveyskirjasto.fi/terveyskirjasto/tk.koti>. Viitattu 22.2.2019.
- Andre Esteva, Brett Kuprel, Roberto A Novoa, Justin Ko, Susan M Swetter, Helen M Blau ja Sebastian Thrun. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639):115, 2017. doi: 10.1038/nature21056.
- Google. Classification: Accuracy, 2019a. URL <https://developers.google.com/machine-learning/crash-course/classification/accuracy>. Viitattu 8.3.2019.
- Google. Classification: Precision and recall, 2019b. URL <https://developers.google.com/machine-learning/crash-course/classification/precision-and-recall>. Viitattu 8.3.2019.
- Google. Classification: Roc curve and auc, 2019c. URL <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc>. Viitattu 14.4.2019.
- Petri Hilli, Timo Ståhl, Marko Merikukka ja Tiina Ristikari. Syrjäytymisen hinta – case investoinnin kannattavuuslaskemasta. *Yhteiskuntapolitiikka*, 82(6):663–675, 2017.
- Blanca E. Himes, Yi Dai, Isaac S. Kohane, Scott T. Weiss ja Marco F. Ramoni. Prediction of chronic obstructive pulmonary disease (copd) in asthma patients using electronic medical records. *Journal of the American Medical Informatics Association*, 16(3):371–379, 2009. doi: 10.1197/jamia.M2846.
- Saurabh Jha ja Eric J. Topol. Adapting to artificial intelligence: radiologists and pathologists as information specialists. *Jama*, 316(22):2353–2354, 2016. doi: 10.1001/jama.2016.17438.

- Fei Jiang, Yong Jiang, Hui Zhi, Yi Dong, Hao Li, Sufeng Ma, Yilong Wang, Qiang Dong, Haipeng Shen ja Yongjun Wang. Artificial intelligence in healthcare: past, present and future. *Stroke and vascular neurology*, 2(4):230–243, 2017. doi: 0.1136/svn-2017-000101.
- Kati Juva. *Alzheimerin tauti*. Kustannus Oy Duodecim, 2018. URL [https://www.terveyskirjasto.fi/terveyskirjasto/tk.koti?p\\_artikkeli=dlk00699](https://www.terveyskirjasto.fi/terveyskirjasto/tk.koti?p_artikkeli=dlk00699). Viitattu 18.3.2019.
- Andreas Kaplan ja Michael Haenlein. Siri, siri, in my hand: Who’s the fairest in the land? on the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1):15–25, 2019. doi: <https://doi.org/10.1016/j.bushor.2018.08.004>.
- Gökhan Karakülah, Oguz Dicle, Özgün Kosaner, Asli Suner, Çağdas Can Birant, Tolga Berber ja Sezin Canbek. Computer based extraction of phenotypic features of human congenital anomalies from the digital literature with natural language processing techniques. *MIE*, sivut 570–574, 2014. doi: 10.3233/978-1-61499-432-9-570. Viitattu 22.2.2019.
- Junghoe Kim, Vince D. Calhoun, Eunsoo Shim ja Jong-Hwan Lee. Deep neural network with weight sparsity control and pre-training extracts hierarchical features and enhances classification performance: Evidence from whole-brain resting-state functional connectivity patterns of schizophrenia. *NeuroImage*, 124:127–146, 2015. doi: 10.1016/j.neuroimage.2015.05.018.
- Sari Koski, Pirjo Ilanne-Parikka, Olli Kurkela, Tiina Jarvala ja Pekka Rissanen. Diabeteksen kustannukset: Lisäsairauksien ilmaantumisen puolittaminen toisi satojen miljoonien säästöt vuodessa. *Diabetes ja lääkäri*, 47(2):13–17, 2018.
- June-Goo Lee, Sanghoon Jun, Young-Won Cho, Hyunna Lee, Guk Bae Kim, Joon Beom Seo ja Namkug Kim. Deep learning in medical imaging: General overview. *Korean Journal of Radiology*, 18(4):570–584, 2017. doi: 10.3348/kjr.2017.18.4.570.
- George F Luger. *Artificial intelligence: structures and strategies for complex problem solving*. Pearson education, 2005. ISBN 978-0-321-54589-3.
- Andrea Mannini, Diana Trojaniello, Andrea Cereatti ja Angelo Sabatini. A machine learning framework for gait classification using inertial sensors: Application to elderly, post-stroke and huntington’s disease patients. *Sensors*, 16(1):134, 2016. doi: 10.3390/s16010134.
- Kanti V. Mardia, John T. Kent ja John M. Bibby. *Multivariate Analysis*. Academic Press, 1997. ISBN 0-12-471250-9.

- Harvey J. Murff, Fern FitzHenry, Michael E. Matheny, Nancy Gentry, Kristen L. Kotter, Kimberly Crimin, Robert S. Dittus, Amy K. Rosen, Peter L. Elkin, Steven H. Brown ja Theodore Speroff. Automated Identification of Postoperative Complications Within an Electronic Medical Record Using Natural Language Processing. *JAMA*, 306(8): 848–855, 08 2011. doi: 10.1001/jama.2011.1204.
- Wendy Oude Nijeweme-d’Hollosy, Lex van Velsen, Mannes Poel, Catharina G.M. Groothuis-Oudshoorn, Remko Soer ja Hermie Hermens. Evaluation of three machine learning models for self-referral decision support on low back pain in primary care. *International Journal of Medical Informatics*, 110:31 – 41, 2018. doi: <https://doi.org/10.1016/j.ijmedinf.2017.11.010>.
- Alireza Osareh ja Bitra Shadgar. Machine learning techniques to diagnose breast cancer. *2010 5th International Symposium on Health Informatics and Bioinformatics*, sivut 114–120. IEEE, 2010. doi: 10.1109/HIBIT.2010.5478895.
- Vimla L. Patel, Edward H. Shortliffe, Mario Stefanelli, Peter Szolovits, Michael R. Berthold, Riccardo Bellazzi ja Ameen Abu-Hanna. The coming of age of artificial intelligence in medicine. *Artificial Intelligence in Medicine*, 46(1):5–17, 2009. doi: 10.1016/j.artmed.2008.07.017.
- Lawrence L Rabiner. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2), 1989. doi: 10.1109/5.18626.
- Sohini Roychowdhury, Dara D. Koozekanani ja Keshab K. Parhi. Dream: diabetic retinopathy analysis using machine learning. *IEEE journal of biomedical and health informatics*, 18(5):1717–1728, 2014. doi: 10.1109/JBHI.2013.2294635.
- Stuart J Russell ja Peter Norvig. *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited, 2016. ISBN 9781292153964.
- Christian Salvatore ja Isabella Castiglioni. A wrapped multi-label classifier for the automatic diagnosis and prognosis of alzheimer’s disease. *Journal of neuroscience methods*, 302:58–65, 2018. doi: <https://doi.org/10.1016/j.jneumeth.2017.12.016>.
- Shai Shalev-Shwartz ja Shai Ben-David. *Understanding machine learning: From theory to algorithms*. Cambridge university press, 2014. ISBN 978-1-107-05713-5.
- Cedric Austen Bardell Smith. Some examples of discrimination. *Annals of Eugenics.*, 13 (4):272–282, 1947. doi: 10.1111/j.1469-1809.1946.tb02368.x.
- Wenqing Sun, Bin Zheng ja Wei Qian. Computer aided lung cancer diagnosis with deep learning algorithms. *Medical imaging 2016: computer-aided diagnosis*, osa 9785, sivu 97850Z. International Society for Optics and Photonics, 2016. doi: 10.1117/12.2216307.



- Nasser H Sweilam, AA Tharwat ja NK Abdel Moniem. Support vector machine for diagnosis cancer disease: A comparative study. *Egyptian Informatics Journal*, 11(2): 81–92, 2010. doi: 10.1016/j.eij.2010.10.005.
- Karoliina Talvitie-Lamberg, Minna Silvennoinen, Hannu Moilanen ja Jari Korpela. Tekoäly sosiaalisen syrjäytymisen ennakoivassa tunnistamisessa - Case THL kouluterveyskysely. *Informaatioteknologian tiedekunnan julkaisuja*, 62:43, 2018.
- Kirsi Tarnanen, Summanen Paula ja Komulainen Jorma. Diabeettinen retinopatia – diabetekseen liittyvä silmäsairaus, 2017. URL [https://www.terveyskirjasto.fi/terveyskirjasto/tk.koti?p\\_artikkeli=khp00059](https://www.terveyskirjasto.fi/terveyskirjasto/tk.koti?p_artikkeli=khp00059). Viitattu 15.3.2019.
- Henni Tenhunen, Petteri Hirvonen, Miika Linna, Olli Halminen ja Iris Hörhammer. Intelligent patient flow management system at a primary healthcare center-the effect on service use and costs. *Decision Support Systems and Education; Studies in Health Technology and Informatics; Volume 255*, sivut 142–146, 2018. doi: 10.3233/978-1-61499-921-8-142.
- THL. Masennus, 2015. URL <https://thl.fi/fi/web/mielenterveys/mielenterveyden-edistaminen/keinoja-mielenterveyden-edistamiseen/time-out-aikalisa-elama-raiteilleen/aikalisaohjaajien-materiaalipaketti/mielenterveys/masennus>. Viitattu 22.2.2019.
- THL. Osallisuus, 2018. URL <https://thl.fi/fi/web/hyvinvointi-ja-terveyserot/eriarvoisuus/hyvinvointi/osallisuus>. Viitattu 22.2.2019.
- K. Vembandasamy, R. Sasipriya ja E. Deepa. Heart diseases detection using naive bayes algorithm. *IJISSET-International Journal of Innovative Science, Engineering & Technology*, 2:441–444, 2015.
- Hertta Vierula. Tekoäly on matkalla lääkärin työkaluksi. *Lääkärilehti*, 72(21):1338 – 1341, 2017.
- Yanling Wu, Yanping Ding, Yoshimasa Tanaka ja Wen Zhang. Risk factors contributing to type 2 diabetes and recent advances in the treatment and prevention. *International Journal of Medical Sciences*, 11(11):1185–1200, 09 2014. doi: 10.7150/ijms.10001.
- Jinn-Yi Yeh, Tai-Hsi Wu ja Chaun-Wei Tsao. Using data mining techniques to predict hospitalization of hemodialysis patients. *Decision Support Systems*, 50(2):439–448, 2011. doi: 10.1016/j.dss.2010.11.001.
- Qing Zhang, Yang Xie, Pengjie Ye ja Chaoyi Pang. Acute ischaemic stroke prediction from physiological time series patterns. *The Australasian medical journal*, 6(5):280, 2013. doi: <http://dx.doi.org/10.4066/AMJ.2013.1650>.