

Tekoälyn hyödyntäminen terveydenhuollossa terveystekijöiden tunnistamiseksi ja ennustamiseksi

Anna Vahteristo¹, Ulla-Mari Kinnunen²

¹ Suomen Terveystalo Oy, Helsinki, Finland; ² Itä-Suomen yliopisto, Sosiaali- ja terveysjohtamisen laitos, Kuopio

Anna Vahteristo, TtM, Kehityspäällikkö, Suomen Terveystalo Oy Helsinki, FINLAND. Sähköposti: anna.vahteristo@terveystalo.com

Tiivistelmä

Kiinnostus tekoälyä kohtaan on lisääntynyt terveydenhuollossa ja sitä koskevaa tutkimusta on tehty jonkin verran esimerkiksi terveystekijöiden ja riskitekijöiden tunnistamiseksi, lääkitysten arvioimiseksi sekä antureiden tuottamien tulosten arvioimiseksi. Tämän integroivan kirjallisuuskatsauksen tarkoituksena oli kuvata aikaisemman kirjallisuuden perusteella, miten tekoälyä on hyödynnetty terveydenhuollossa erilaisten terveystekijöiden tunnistamiseksi ja riskien terveysvaikutusten ennustamiseksi. Katsauksen tavoitteena oli lisätä ymmärrystä tekoälyn hyödyntämismahdollisuuksista ennaltaehkäisevän terveydenhuollon näkökulmasta ja tunnistaa sen mahdollisuuksia myös työterveyshuollossa. Katsausta varten tehtiin hakuja kansainvälisiin tietokantoihin pyrkien integroivan kirjallisuuskatsauksen menetelmin tuomaan uutta näkökulmaa viimeisen viiden vuoden ajalta tekoälyn hyödyntämisestä erityisesti terveystekijöiden tunnistamiseksi ja ennustamiseksi.

Tämän integroivan kirjallisuuskatsauksen perusteella tekoälyä on hyödynnetty erilaisten terveystekijöiden ja riskitekijöiden tunnistamiseksi hyödyntämällä potilastietojärjestelmistä ja muista terveydenhuollon järjestelmistä saatavaa rakenteista tai tekstimuotoista tietoa. Mallien rakentamisessa on käytetty useita eri menetelmiä tai niiden yhdistelmiä. Mallien hyvyyden arvioiminen eri menetelmien ja eri riskitekijöiden välillä on haasteellista, mutta tutkimustulokset ovat lupaavia ja osoittavat tekoälyn tuovan uusia mahdollisuuksia erilaisten riskitekijöiden tunnistamiseen sekä tunnistamiseen perustuvien ennustemallien rakentamiseen.

Tekoäly mahdollistaa uudenlaisten potilastietoa hyödyntävien menetelmien kehittämisen terveydenhuollon käyttöön. Erilaiset tekoälyyn perustuvat mallit terveystekijöiden ja riskitekijöiden tunnistamiseksi ja ennustamiseksi tukevat osaltaan ennaltaehkäisevän terveydenhuollon kehittämistä. Tutkimusta tarvitaan kuitenkin lisää erilaisten menetelmien hyvyyden arvioimiseksi. Tekoälyn hyödyntäminen riskitekijöiden tunnistamiseksi ja ennustemallien luomiseksi edellyttää myös eettistä keskustelua uudenlaisten menetelmien käyttämisessä.

Avainsanat: tekoäly, terveydenhuolto, ennaltaehkäisy, riskitekijät, kirjallisuuskatsaus

Abstract

The interest in using artificial intelligence in health care has increased. Previous studies have for example tried to identify health risks and risk factors, to evaluate medications and to evaluate the results received from different sensors. The objective of this integrative review was to describe how artificial intelligence has been used in health care to identify or predict health risks and risk factors. The aim of this review was to provide more information about how artificial intelligence can be used in preventive health care, and in occupational health care. Searches for recent literature were conducted in scientific databases following the principles of integrative review.

According to this integrative review, artificial intelligence has been used to identify different health risks and risk factors by using structured and unstructured data from the electronic medical records and other applications used in health care. The methods of the models used to identify or to predict the health risks or risk factors vary. Evaluation of the different methods used in the models is difficult, but generally the results have been promising and clearly indicate that artificial intelligence can be used to identify and predict health risks and risk factors.

Artificial intelligence provides new methods for the use of health care. Different models of identifying and predicting health risks and risk factors can promote the development of preventive health care. However, more research is needed to evaluate the different models. Also, the new methods raise the need for ethical discussion of the use of artificial intelligence to identify and predict health risks and risk factors and how information obtained can be used..

Keywords: AI (artificial intelligence), health care, prevention & control, risk factors, review literature as topic

Johdanto

Kiinnostus tekoälyä kohtaan on kasvanut viime vuosina sekä yleisesti, että terveydenhuollon toimintaympäristössä. Tämä kiinnostus näkyy myös Maailman terveysjärjestön (WHO) ja Kansainvälisen televiestintäliiton (ITU) yhteisessä aloitteessa tekoälyn hyödyntämiseksi terveydenhuollossa [1] sekä Euroopan komission linjauksessa eurooppalaisesta lähestymistavasta tekoälyä koskeviin investointeihin ja eettisiin ohjeistuksiin [2]. WHO:n ja ITU:n yhteistyönä muodostettu työryhmä pyrkii muun muassa luomaan standardoidun viitekehysten, jonka avulla pyritään arvioimaan tekoälyä hyödyntäviä metodeja, joiden avulla pyritään tunnistamaan terveyttä, diagnosointia, hoidon kiireellisyyttä ja hoitotoimenpiteitä [3]. Euroopan komissio puolestaan nostaa linjauksessaan eurooppalaisen kilpailukyvyyn vahvistamisen tekoälyä hyödyntämällä myös terveydenhuollon sektorilla [2]. Tekoälyn hyödyntäminen liittyy vahvasti WHO:n tavoitteeseen tunnistaa keinoja yhdistää teknologiaa olemassa oleviin terveyspalveluihin, ja siten tu-

kea terveyden edistämistä sekä yhtäläistä oikeutta ja mahdollisuutta terveyteen [4].

Myös Suomessa on tunnistettu tekoälyn mahdollisuudet terveydenhuollossa. Valtioneuvoston [5] periaatepäätöksessä älykkäästä robotiikasta ja automaatiosta on nostettu tavoitteeksi hyödyntää automaatiota ja älykästä robotiikkaa teollisuuden lisäksi myös muilla sektoreilla, kuten sosiaali- ja terveydenhuollossa. Sosiaali- ja terveysministeriössä (STM) on käynnissä hyvinvointialalla hyödynnettävän tekoälyn ja robotiikan kehittämiseen liittyvä Hyvinvoinnin AiRo-ohjelma, jonka avulla pyritään tekoälyn ja robotiikan keinoin tukemaan esimerkiksi kotona asumista, lääkehoitoa ja hyvinvoinnin valmennusta [6]. Näiden ja muiden tekoäly- ja robotiikkahankkeiden avulla voidaan löytää uusia keinoja sairauksien hoitoon ja ennaltaehkäisyyn sekä terveyden edistämiseksi, ja siten vastata valtioneuvoston periaatepäätöksen tavoitteeseen robotiikan ja automaation edistämiseksi [7]. Tutkimuksen näkökulmasta tekoälyosaaminen on Suomessa kansainvälisesti tarkasteltuna hyvällä tasolla, ja yksi tulevaisuuden painopistealueista voisi olla tekoälyratkaisujen eettisyyden ja

luotettavuuden varmistaminen esimerkiksi terveyden- ja sairaudenhoidossa [8].

Tekoälyllä tarkoitetaan ihmisen teknisin menetelmin valmistamia, yleensä erilaisia järjestelmiä, jotka kykenevät jonkinlaiseen älykkääseen toimintaan [9]. Tekoäly on tietojenkäsittelytieteen keskeinen alue, joka sisältää muun muassa koneoppimisen, luonnollisen kielen käsittelyn, neuroverkot ja robotiikan [10]. Pavel Hamet ja Johanne Tremblay [11] jakavat lääketieteessä hyödynnetyn tekoälyn fyysiseen ja virtuaaliseen tekoälyyn, joista fyysisellä tekoälyllä tarkoitetaan robotiikkaa, ja virtuaalisella tekoälyllä koneoppimista sekä algoritmien hyödyntämistä lääketieteessä. Tässä artikkelissa tekoälyä tarkastellaan yläkäsitteenä sisältäen kaikki sen alle kuuluvat alakäsitteet.

Uusien teknologioiden, kuten tekoälyn, yhdistäminen olemassa oleviin terveyspalveluihin terveyden edistämisen tukemiseksi [4] sekä terveysneuvonnassa ja terveydenhuollon kehittämiseksi potilaiden tarpeita vastaaviksi [11] on yhä tärkeämmässä roolissa pitkäaikais-sairauksien yleistyessä [12]. WHO:n tilastojen [12] mukaan pitkäaikais-sairauksista aiheutuvat kuolemat ovat yleistyneet yleisesti maailmalla, aiheuttaen keskimäärin 70% kuolemista, Suomessa jopa 93% ja näistä 10% ennaltaehkäiseviä. Yleisimpiä pitkäaikais-sairauksia ovat sydän- ja verisuonisairaudet, diabetes, syövät sekä krooniset hengityselinsairaudet. Kaikkien edellä kuvattujen pitkäaikais-sairauksien taustalla on riskitekijöitä, joihin voidaan vaikuttaa terveystieteellisten keinojen lisäksi ennaltaehkäisevän terveydenhuollon avulla. [12] Ennaltaehkäisevän terveydenhuollon mahdollistamiseksi pitkäaikais-sairauksien tunnistamiseen tulisi pyrkiä mahdollisimman varhaisessa vaiheessa. Suomessa työterveyshuollon piirissä on lähes kaksi miljoonaa henkilöä, mikä tarkoittaa 84% työikäisestä työvoimasta [13]. Vaikka työterveyshuollon lakisääteinen velvollisuus koskeekin työstä johtuvien terveysvaarojen ja -haittojen syntymisen ehkäisemistä, sekä työntekijöiden terveyden, työkyvyn ja turvallisuuden edistämistä ja turvaamista, voidaan työterveyshuollon palveluita täydentää työterveyspainotteisella sairaanhoidolla ja muilla palveluilla [14]. Tämä osaltaan lisää työterveyshuollon vaikutusmahdollisuuksia työikäisen väestön

terveyden edistämisessä, esimerkiksi terveysriskejä tunnistamalla.

Hametin ja Tremblayn [11] mukaan tekoälyä koskevaa kirjallisuutta on runsaasti, mutta toisaalta se on vielä moninaista ja jäsentymätöntä. Tämän integroivan katsauksen avulla pyritään luomaan yleisnäkemyksiä viimeaikaisesta terveydenhuollossa hyödynnetystä tekoälystä. Katsauksen tavoitteena on lisätä ymmärrystä tekoälyn hyödyntämismahdollisuuksista erityisesti ennaltaehkäisevän terveydenhuollon näkökulmasta.

Tutkimuksen tarkoitus ja tutkimuskysymykset

Tämän integroivan katsauksen tarkoituksena on kuvata aikaisemman kirjallisuuden perusteella, miten tekoäly on hyödynnetty terveydenhuollossa erilaisten terveysriskien tunnistamiseksi ja riskien terveysvaikutusten ennustamiseksi. Katsauksen tavoitteena on lisätä ymmärrystä tekoälyn hyödyntämismahdollisuuksista ennaltaehkäisevän terveydenhuollon näkökulmasta ja tunnistaa sen mahdollisuuksia myös työterveyshuollossa. Tavoitteena on myös tunnistaa menetelmiä, joiden avulla voitaisiin yhä varhaisemmassa vaiheessa tunnistaa erilaisia riskitekijöitä ja riskiryhmiä ja siten tukea ennaltaehkäisevän terveydenhuollon kehittämistä.

Tutkimuskysymykset ovat:

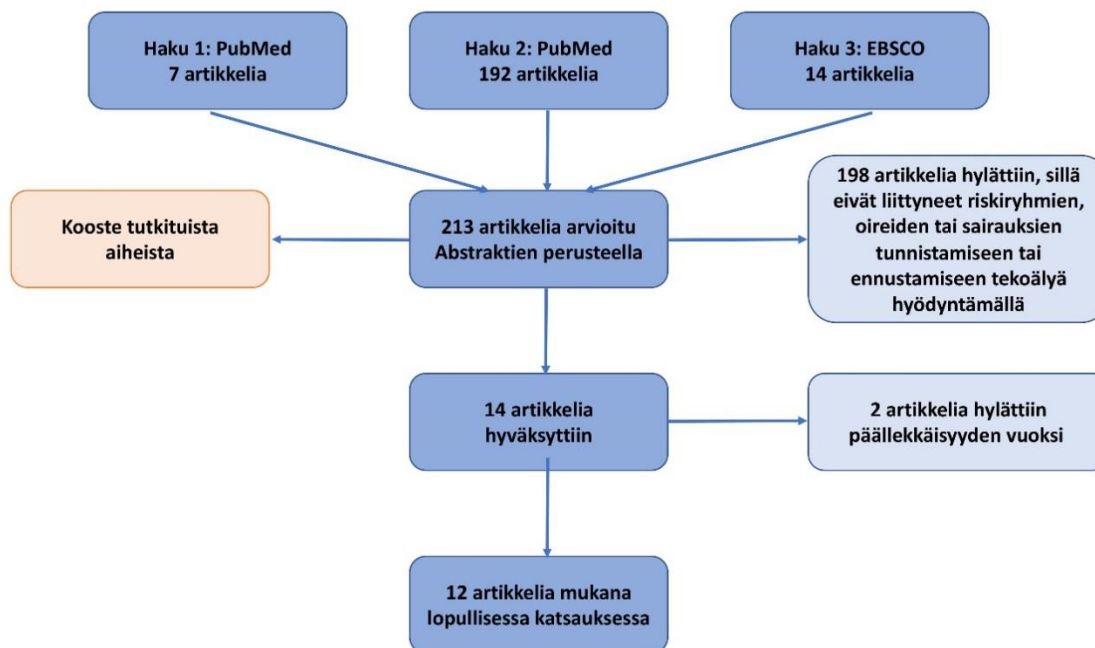
1. Miten tekoälyä on hyödynnetty terveydenhuollossa terveysriskien ja riskitekijöiden tunnistamiseksi?
2. Miten tekoälyä on hyödynnetty terveydenhuollossa terveysriskejä ja riskitekijöitä koskevissa ennustemalleissa?
3. Mitä tekoälyn menetelmiä on käytetty terveysriskien ja riskitekijöiden tunnistamiseksi ja ennustamiseksi?
4. Miten käytettyjen tekoälyn menetelmien hyvyttä on arvioitu?

Aineistot ja menetelmät

Tutkittavan aiheen tarkasteluun valittiin menetelmäksi integroiva katsaus, joka mahdollistaa ilmiön kriittisen tarkastelun ja synteisien tekemisen, pyrkien tuomaan esiin uusia näkökulmia tarkasteltavasta aiheesta [15]. Kuvailevaan kirjallisuuskatsaukseen kuuluva integroiva katsaus mahdollistaa laaja-alaisen yleiskatsauksen tekemisen ilman järjestelmälliselle kirjallisuuskatsaukselle asetettuja metodisia vaatimuksia [16], kuten aineiston tarkkaa rajaamista tai mukaan otettujen tutkimusten laadun arviointia. Vaikka integroiva katsaus voidaan toteuttaa usein eri tavoin, edellyttää se aina katsauksen tekovaiheiden kuvaamisen ja raportoimisen yleisesti sovitujen käytäntöjen mukaisesti, järjestelmällisesti [15-16].

Tätä katsausta varten tehtiin syys-lokakuussa 2018 kirjallisuushakua kansainvälisistä tietokannoista. Aiheeseen liittyvän kasvavan kiinnostuksen ja menetelmien kehittymisen vuoksi katsaus rajattiin vuosille 2013-2018 mahdollisimman ajankohtaisen tiedon saamiseksi. Kirjallisuushakuprosessi on esitetty kuviossa 1. Ensimmäi-

nen kirjallisuushaku suoritettiin PubMed-tietokantaan pyrkien löytämään tietoa tekoälyn hyödyntämisestä työkykyyn liittyen, sillä työkyvyn ylläpitäminen edellyttää terveysriskien ja riskitekijöiden tunnistamista ja ennustamista. Hakusanoina käytettiin "work ability", "artificial intelligence" "healthcare" ja "health care". Lisärajausena oli englanninkieliset vertaisarvioidut ja sähköisessä muodossa saatavat artikkelit. Haku tuotti vain seitsemän artikkelia, minkä vuoksi hakukriteereitä väljennettiin ja tarkasteluun otettiin yleisemmin terveydenhuollossa tehdyt tutkimukset. Myös toinen haku suoritettiin PubMed-tietokantaan, hyödyntäen hakusanoja "artificial intelligence", "health care", "healthcare" ja "medical information". Lisärajausena oli jälleen englanninkieliset, vertaisarvioidut ja sähköisenä saatavat artikkelit. Haku tuotti yhteensä 192 artikkelia. Kolmas haku tehtiin EBSCOhost Academic Search Premier-tietokantaan samoin hakuperustein, kuin toinen haku. Tämä haku tuotti 62 artikkelia, joista kokoteksti oli saatavilla 14 artikkelista.



Kuvio 1. Kirjallisuushakuprosessin kuvaus.

Kaikkiaan tuloksena saatiin 198 artikkelia, joista käytiin otsikoiden lisäksi läpi niiden tiivistelmät. Tässä vaiheessa tarkasteltiin artikkeleiden teemoja yleisellä tasolla pyrkien saamaan käsitystä mihin aihealueisiin liittyen tutkimuksia oli tehty. Varsinaiseen kirjallisuuskatsaukseen otettiin mukaan vain artikkelit, jotka kohdistuivat riskitekijöiden tunnistamiseen ja niihin liittyvien ennustemallien luomiseen. Mahdollisten päällekkäisyyksien huomioimisen jälkeen katsaukseen otettiin lopulta mukaan 12 artikkelia.

Aineiston analyysissä hyödynnettiin kuvailevaa synteesiä. Synteesissä aineistoa luokiteltiin tunnistettujen tutkimuksen kohteena olevien sairauksien, tekoälyn menetelmien sekä näiden menetelmien hyvyyden arviointimittareiden perusteella. Luokituksista pyrittiin tunnistamaan myös tarkempia alakäsitteitä laajemman ymmärryksen muodostamiseksi

Tulokset

Tekoälyn hyödyntäminen terveydenhuollossa terveysriskien ja riskitekijöiden tunnistamiseksi ja ennustamiseksi

Tekoälyä hyödynnetään jo nyt terveydenhuollossa. Tätä katsausta varten tehdyn kirjallisuushaun tuottamia

tuloksia tarkasteltiin yleisellä tasolla, jotta saatiin tarkempi kuva tekoälyn hyödyntämisestä terveydenhuollossa vuosina 2013-2018. Tämän tarkastelun perusteella tekoälyä on hyödynnetty esimerkiksi erilaisten riskiryhmien ja oireiden tunnistamiseen, lääkityksen arvioimiseen, hoitotoimenpiteiden valintaan, sekä erilaisten ennustemallien luomiseen ja yhteyksien tunnistamiseen liittyen sairauksien tai hoidon ennusteisiin. Tekoälyä on hyödynnetty myös narratiivisessa muodossa olevan tiedon käytön mahdollistamiseksi esimerkiksi luonnollisen kielen käsittelyllä, sekä erilaisten anturien tuottamien tulosten arvioinnissa. Tämän yleisellä tasolla tehdyn tarkastelun perusteella tekoälyn käyttömahdollisuudet terveydenhuollossa ovat moninaiset, mutta tässä integroivassa katsauksessa keskityttiin tekoälyn hyödyntämismahdollisuuksien tarkasteluun ennaltaehkäisyssä näkökulmasta.

Tekoälyn menetelmiä on hyödynnetty esimerkiksi aivoaneurysmaan [17], osteoporoosiin [18], mielenterveyden häiriöihin [19,20], dementiaan [21], runsaaseen virtsahappopitoisuuteen [22] ja sydänsairauksiin [23-25] liittyvien riskitekijöiden tunnistamiseksi. Lisäksi tekoälyn menetelmiä on hyödynnetty yleisemmin sairauksiin liittyvien riskitekijöiden [26] ja terveydentilojen tunnistamiseksi [27,28]. Taulukossa 1 on kuvattu mihin sairauksiin tai terveydentiloihin liittyen terveysriskejä ja riskitekijöitä on tunnistettu tekoälyn avulla.

Taulukko 1. Tutkimuksen kohteena oleva sairaus, jota pyritään tunnistamaan tai ennustamaan.

Tutkimus	Sairaus, joka pyritään tunnistamaan	Tunnistaminen/ennustaminen
Castro ym. 2016 (USA)	aivoaneurysma	tunnistaminen
Cruz ym. 2018 (Brasilia)	osteoporoosi	tunnistaminen
Ford ym. 2016 (UK)	yleinen terveydentila	tunnistaminen
Ichikawa ym. 2016 (Japani)	runsas virtsahappopitoisuus	tunnistaminen ja ennustaminen
Jackson ym. 2017 (UK)	mielenterveydenhäiriöt	tunnistaminen
Jonnagoddala ym. 2015 (Australia)	sydänsairaudet	tunnistaminen
Kim ym. 2017 (Korea)	dementia	tunnistaminen ja ennustaminen
Liu ym. 2015 (Taiwan)	ylenen terveydentila	tunnistaminen
Singh ym. 2018 (Intia)	sydänsairaudet	tunnistaminen ja ennustaminen
Skeppstedt ym. 2014 (Ruotsi)	yleinen terveydentila	tunnistaminen
Torii ym. 2015 (USA)	sydänsairaudet	tunnistaminen ja ennustaminen
Tuarob ym. 2017 (USA)	mielenterveydenhäiriöt	tunnistaminen ja ennustaminen

Viidessä tutkimuksessa on tunnistamisen lisäksi pyritty terveystarkastuksien tai riskitekijöiden ennustamiseen (ks. Taulukko 1). Ichikawa tutkimusryhmineen [22] yhdisti dataa terveystarkastuksista eri vuosilta runsaan virtsa-happoisuuden ennustemallia varten. Myös ikääntyvien dementian ennustamiseksi hyödynnettiin säännöllisistä terveystarkastuksista saatuja tietoja muodostaen niistä aikasarjoja [21]. Tuarob tutkimusryhmineen [20] puolestaan keräsi mielenterveyden riskitekijöiden tunnistamiseksi tietoa kolmeen eri otteeseen kahdeksan kuukauden aikana. Sekä Singhin tutkimusryhmän [24], että Toriin tutkimusryhmän [25] sydänsairauksien ennustemallit puolestaan perustuivat riskitekijöiden tunnistamiseen datasta.

Potilastietojärjestelmissä ja muissa lähdejärjestelmissä olevaa tietoa on hyödynnetty mahdollisuuksien mukaan rakenteisessa muodossa. Rakenteisessa muodossa olevia tietoja on tutkimuksia varten poimittu erilaisista mittaustuloksista [18,22,24,26] ja kyselyistä [18,20]. Rakenteista tietoa on saatu myös lääkityksistä [23,27], diagnooseista [17,19,21,24, 27] ja toimenpiteistä [17,27]. Potilastietojärjestelmissä on kuitenkin edelleen paljon tietoa vain narratiivisessa muodossa [17]. Tekstimuotoisen tiedon hyödyntämistä varten teksteistä on poimittu avainsanojen avulla tietoa ja muodostettu siten tarvittavia luokitteluja [17,19,23,26,28]. Lisäksi tutkimuksissa on hyödynnetty luonnollisen kielen käsit-

telymenetelmiä [17,19,23,25-28]. Luonnollisen kielen käsittelyllä (Natural Language Processing, NLP) tarkoitetaan erilaisia tietoteknisiä menetelmiä, joiden avulla voidaan analysoida ja esittää luonnollisesti esiintyviä tekstejä erilaisilla kielen analysointiin tarkoitetuilla menetelmillä ja siten pyrkiä saavuttamaan ihmisille tyypillinen tapa käsitellä kieltä erilaisissa tehtävissä ja sovelluksissa [29]. Katsauksen perusteella kertomustietoja on hyödynnetty sekä rakenteista tietoa täydentävänä [17,23], että ainoana tiedonlähteenä [19,25-28].

Terveystarkastuksien ja riskitekijöiden tunnistamiseksi ja ennustamiseksi käytetyt tekoälyn menetelmät

Tutkimuksissa on hyödynnetty useita tekoälyn menetelmiä. Cruz tutkimusryhmineen [18] listasi kirjallisuuskatsauksessaan osteoporoosin tunnistamiseksi käytetyiksi tekoälyä hyödyntäviksi menetelmiksi esimerkiksi tukivektorikoneet, random forest, neuroverkot ja logistisen regressiomallin. Fordin tutkimusryhmän [27] laatimassa systemaattisessa kirjallisuuskatsauksessa puolestaan kuvattiin erilaisten terveydentilojen tunnistamiseksi potilaskertomusteksteistä luonnollisen kielen käsittelyn lisänä sääntöpohjaiset algoritmit, Naïve Bayes -luokittelija, päätöspuut ja neuroverkot. Myös yksittäisissä tutkimuksissa käytetyt menetelmät vaihtelivat. Taulukossa 2 on kuvattu katsauksessa tarkastelluissa tutkimuksissa hyödynnetty menetelmät.

Taulukko 2. Tutkimuksissa käytettyjä tekoälyn menetelmiä.

Tutkimus	Käytetyt menetelmät
Castro ym. 2016 (USA)	Luonnollisen kielen käsittely, Naïve-Bayesin -luokittelija, logistinen regressiomalli, luokittelualgoritmit
Cruz ym. 2018 (Brasilia)	Päätöspuut, tukivektorikoneet, logistinen regressiomalli, gaussin sekoitemalli, oppiva vektorinen kvantisointi, luokittelualgoritmit, neuroverkot
Ford ym. 2016 (UK)	Luonnollisen kielen käsittely, päätöspuut, sääntöpohjaiset menetelmät, Naïve Bayesin -luokittelija, tukivektorikoneet, logistinen regressiomalli, luokittelualgoritmit, neuroverkot
Ichikawa ym. 2016 (Japani)	Päätöspuut, logistinen regressiomalli
Jackson ym. 2017 (UK)	Luonnollisen kielen käsittely, tukivektorikoneet,
Jonnagoddala ym. 2015 (Australia)	Luonnollisen kielen käsittely, sääntöpohjaiset mallit, Naïve Bayesin -luokittelija
Kim ym. 2017 (Korea)	Tukivektorikoneet,
Liu ym. 2015 (Taiwan)	Luokittelualgoritmit
Singh ym. 2018 (Intia)	Neuroverkot, datan louhinta
Skeppstedt ym. 2014 (Ruotsi)	Luonnollisen kielen tunnistaminen
Torii ym. 2015 (USA)	Luonnollisen kielen tunnistaminen, Conditional random fields (CRF), päätöspuut, Naïve Bayesin -luokittelija, tukivektorikoneet, luokittelualgoritmit
Tuarob ym. 2017 (USA)	Päätöspuut, vektoriautoregressio (VAR), tukivektorikoneet, logistinen regressiomalli, multi-layer perception (MLP), Gaussin regressioprosessi, luokittelualgoritmit

Terveysriskien ja riskitekijöiden tunnistamiseksi ja ennustamiseksi hyödynnettyjen tekoälyn menetelmien hyvyden arvioiminen

Tekoälyn avulla luotuja tunnistamisen ja ennustamisen malleja voidaan arvioida eri kriteerein. Alpaydinin [30] mukaan mallien arviointia voidaan tehdä sen perusteella, miten mallin tuomat tulokset ovat luokiteltavissa. Näitä luokkia ovat oikeat positiiviset, oikeat negatiiviset, väärät positiiviset ja väärät negatiiviset. Oikeat positiiviset (true positives, tp) ovat niitä, jotka luokittelussa ovat ohjautuneet tarkastelun kohteena olevaan luokkaan ja sinne myös kuuluvat. Oikeat negatiiviset (true negatives, tn) puolestaan ovat niitä, jotka eivät ole ohjautuneet tarkasteltavaan luokkaan, eivätkä myöskään sinne kuuluisi. Väärät positiiviset (false positives, fp) taas ovat virheellisesti ohjautuneet tarkasteltavaan luokkaan ja väärät negatiiviset (false negatives, fn) kuuluisivat tarkasteltuun luokkaan, mutta eivät ole sinne ohjautuneet. Keskeisiä arvioinnin mittareita ovat tarkkuus (precision), herkkyys (recall), sekä johdonmukai-

suus (specificity). Tarkkuus kuvaa sitä kuinka suuri osa positiivisiksi luokitelluista on oikeasti positiivisia ($tp/(tp+fp)$), herkkyys taas kuinka suuri osa positiivisista näytteistä tunnistetaan positiivisiksi ($tp/(tp+fn)$) ja johdonmukaisuus sitä kuinka hyvin tunnistetaan negatiiviset ($tn/(tn+fp)$). Ideaalisesti oikeiden positiivisten osuus kokonaisuudesta lähestyy arvoa 1 ja väärin positiivisten määrä arvoa 0. [30.] Edellisten lisäksi tulosten arvioinnissa on hyödynnetty F-arvoa, joka lasketaan herkkyyden ja tarkkuuden avulla ($2*(herkkyys*tarkkuus)/(herkkyys+tarkkuus)$) [27]. Oikeiden positiivisten osuuden lähestyessä ideaalisesti arvoa 1 ja väärin positiivisten osuuden arvoa 0, myös näistä johdetut edellä kuvatut laskennalliset, mallien hyvyttä kuvaavat arvot lähestyvät ideaalisesti arvoa 1. Tässä katsauksessa tarkasteltujen tutkimusten arviointimenetelmät vaihtelivat, ja edellä esitettyjen mallien hyvyttä arvioivien menetelmien lisäksi on käytetty myös muita menetelmiä. Käytetyt arviointimenetelmät sekä keskeiset arvot on esitetty taulukossa 3.

Taulukko 3. Mallien arvioinnissa käytetyt menetelmät ja keskeiset tulokset.

Tutkimus	Tarkkuus	Herkkyys	Johdonmukaisuus	F-arvo	Muut menetelmät
Castro ym. 2016 (USA)	0.88-0.91	0.59-0.78	0.95		NPV ¹ AUROC ²
Cruz ym. 2018 (Brasilia)	0.77-0.98				
Ford ym. 2016 (UK)	0.78-0.86 (menetelmittäin)	0.80-0.96 (menetelmittäin)	0.95-0.97 (menetelmittäin)		NPV ¹ AUROC ²
	0.54-0.98 (riski- tekijöittäin)	0.48-0.99 (riskitekijöittäin)	0.93-0.99 (riskitekijöittäin)		
Ichikawa ym. 2016 (Japani)		0.70-0.74	0.71-0.77		MCC ³ BSS ⁴
Jackson ym. 2017 (UK)	0.84-0.90	0.85-0.98		0.88-0.91	
Jonnagoddala ym 2015 (Austra- lia)	0.81 (koko malli)	0.85 (koko malli)		0.83 (koko malli)	
	0.53-0.97 (osa-alueet)	0.73-0.97 (osa-alueet)		0.61-0.97 (osa-alueet)	
Kim ym. 2017 (Korea)	0.89-0.90 (aikasarjat)	0.72-0.75 (aikasarjat)		0.80-0.81 (aikasarjat)	Accuracy
Liu ym. 2015 (Taiwan)					MAP ⁵
Singh ym. 2018 (Intia)	1.0	1.0		1.0	AUROC ²
Skeppstedt ym. 2014 (Ruotsi)	0.72-0.95	0.65-0.82		0.69-0.88	
Torii ym. 2015 (USA)	0.82-0.96	0.74-0.98		0.79-0.96	
Tuarob ym. 2017 (USA)					DAC ⁶ , MAE ⁷ , MAPE ⁸ , MSE ⁹ , RMSE ¹⁰

NPV¹ = negatiivinen ennustearvo (negative predictive value)

AUROC² = ROC-käyrän alle jäävä pinta-ala (area under ROC curve)

MCC³ = Matthews'n korrelaatiokerroin (Matthews correlation coefficient)

BSS⁴ = Brierin suhteellinen todennäköisyysarvo (Brier skill score)

MAP⁵ = keskimääräinen keskitarkkuus (mean average precision)

DAC⁶ = suunnallinen tarkkuus (directional accuracy)

MAE⁷ = keskimääräinen keskipoikkeama (mean average error)

MAPE⁸ = keskimääräisten prosenttinvirheiden keskiarvo (mean average percentage error)

MSE⁹ = keskineliövirhe (mean square error)

RMSE¹⁰ = keskineliövirheen neliöjuuri (root mean square error)

Laadittujen tunnistamisen ja ennustamisen mallien arviointituloksissa oli eroja. Sekä Fordin tutkimusryhmän [27], että Cruzin tutkimusryhmän [18] kirjallisuuskatsauksissa vertailtiin tarkastelun kohteena olevien riskitekijöiden tunnistamiseksi käytettyjen menetelmien välisiä eroja, ja jonkin verran eroavaisuuksia mallien välillä oli tunnistettavissa. Tutkimuksissa oli erilaisia menetelmiä käytetty myös rinnakkain, pyrkimyksenä vertailla tuloksia ja siten luoda mahdollisimman hyvä malli riskitekijöiden tai riskiryhmien tunnistamiseksi. Myös näissä mallien välillä oli pieniä eroja tunnistettavissa. [20,22.] Yhdistämällä erilaisia menetelmiä samaan malliin pystyttiin tunnistamisen ja ennustamisen luotavuutta lisäämään [17,19,23]. Mallien hyvyyteen vaikutti myös tutkittava terveysriski. Vaikka Fordin tutkimusryhmän [27] kirjallisuuskatsauksessa itse menetelmien väliset erot olivatkin pienet tarkasteltaessa eri terveydentilojen tunnistamista, vaihtelivat mallien tarkkuudet ja herkkyydet paljon terveydentilojen välillä. Toisaalta myös yksittäisten muuttujien herkkyydessä ja tarkkuudessa havaittiin vaihtelua. Näin ollen lopullisen mallin lisäksi tulee huomioida vaihtelut eri muuttujien tunnistamisen osalta [23,25]. Erityisesti ennustemalleissa myös aikamuuttujalla oli vaikutusta mallin hyvyyteen, jolloin tietyn seurantavälin ennustemallin herkkyys ja tarkkuus oli parempi kuin toisen [21]. Vaikka tulosten arviointien toteutuksissa oli eroja, kaikkiaan tutkimustulosten nähtiin osoittavan käytettyjen tekoälyä hyödyntävien menetelmien mahdollisuudet riskitekijöiden tunnistamiseksi [19,20].

Pohdinta

Tämän integroivan kirjallisuuskatsauksen tarkoituksena oli kuvata tekoälyn hyödyntämistä terveydenhuollossa terveysriskien ja riskitekijöiden tunnistamiseksi ja siten lisätä ymmärrystä aiheesta yleisellä tasolla. Kiinnostus tekoälyä kohtaan on kasvanut niin yleisesti kuin terveydenhuollon toimintaympäristössä. Tekoäly on katsauksen mukaan hyödynnetty erilaisten terveysriskien sekä riskitekijöiden tunnistamiseksi ja ennustamiseksi. Riskitekijöiden tunnistamista varten luoduissa malleissa oli hyödynnetty potilastietojärjestelmistä vain rakenteista [20-22,24] tai tekstimuotoista tietoa [19,25,26] tai näitä

molempia toisiaan täydentäen [17,23]. Katsauksessa mukana olleiden tutkimusten perusteella potilastietojärjestelmistä saatavaa rakenteista ja tekstimuotoista tietoa yhdistämällä saatiin muodostettua luotettavimmat mallit [17]. Myös muilta osin tunnistamis- ja ennustemallien luomisessa on hyödynnetty useita erilaisia menetelmiä [18,27] tai käytetty useamman menetelmän yhdistelmää [17,19,23]. Tämän integroivan katsauksen perusteella mahdollisuuksia mallien luomisessa käytettävien menetelmien osalta on paljon ja parhaan mahdollisen mallin löytämiseksi tarvitaan useamman menetelmän testaamista.

Mallien vertailu niiden hyvyyden perusteella osoittautui tämän katsauksen perusteella haasteelliseksi. Vaikka yleisimmin käytettyjä mittareita olivat tarkkuus, herkkyys ja johdonmukaisuus, myös muita arviointimittareita oli tutkimuksissa käytetty. Fordin tutkimusryhmineen [27] toteaaakin oman kirjallisuuskatsauksensa pohdinnassa, että menetelmien arviointien raportointia tulisi standardoida. Katsauksessa mukana olleiden tutkimusten tuloksiin oltiin kuitenkin pääsääntöisesti tyytyväisiä, sillä niiden perusteella niin rakenteista kuin myös tekstimuotoista tietoa käsittelemällä tekoälyä hyödyntävien menetelmin, pystyttiin tunnistamaan erilaisia riskitekijöitä [19,20]. Toisena haasteena tulosten arvioinnissa on konsensuksen puute liittyen siihen, mikä on kyllin hyvä tulos terveydenhuollon malleille ja minkä verran virheitä voidaan hyväksyä [27]. Rakennettaessa tunnistamisen ja ennustamisen malleja terveydenhuollon ympäristössä, tulee tuloksia arvioitaessa huomioida myös eettiset näkökulmat, sillä pienikin virhemarginaali saattaa suurissa massoissa tarkoittaa satoja virheellisesti tunnistettuja henkilöitä tai pienissä määrissä väärin diagnosoituja yksilöitä. Eettiset näkökulmat tuleekin huomioida siinä, millainen painoarvo tuloksille annetaan ja miten tuloksia tullaan jatkossa hyödyntämään. Myös Euroopan komissio [2] on nostonut esiin tekoälyn eettisen näkökulman, todeten että tekoälyn käyttö saattaa herättää kysymyksiä esimerkiksi siitä, millaisia vaikutuksia sillä on oikein periaattein toteutettuun päätöksentekoon. Vuoden 2018 lopussa Euroopan komissio [31] onkin julkaissut luonnoksen Luotettavaa tekoälyä koskevasta eettisestä ohjeistuksesta, jonka tarkoituksena on varmistaa, että tekoäly tuottaa par-

haan mahdollisen hyödyn, minimoiden siihen liittyvät riskit pyrittäessä vahvistamaan ihmisten hyvinvointia. Eettisten kysymysten lisäksi tutkimusten tulosten tarkastelun näkökulmasta haasteena on myös tunnistettu tutkimusjoukkojen homogeenisuus, minkä vuoksi mallien hyödyntämiseksi laajemmin tarvitaan vielä lisää tutkimusta [18].

Katsauksen luotettavuuteen kiinnitettiin huomiota koko prosessin ajan noudattaen hyvää tieteellistä käytäntöä sen kaikissa vaiheissa [32]. Katsausta tehdessä hyödynnettiin ennalta määriteltyä hakuprosessia mukaanotto- ja poissulkukriteerein, yleisesti käytössä olevia termejä hakusanoina, sekä vertaisarvioituja kansainvälisiä lähdejulkaisuja. Katsaus on kuitenkin toteutettu yleisellä tasolla ja antaa siten vasta yleiskuvaa aiheesta. Lisäksi hakujen tekeminen useampaan tietokantaan olisi saatanut tuoda katsaukseen lisää kokonaisuuden kannalta hyviä tutkimuksia. Tämän integroivan katsauksen perusteella tutkimusta tulisikin jatkaa systemaattisemmalla katsauksella laajemman kuvan saamiseksi sekä aiheesta yleisesti, että parhaiden mahdollisten käytäntöjen ja menetelmien tunnistamiseksi. Lisäksi tarvitaan arviointikriteereiden standardisoinnista sekä keskustelua tulosten hyödynnettävyydestä eettisistä näkökulmista.

Johtopäätökset

Tekoälyn hyödyntämisen mahdollisuudet terveydenhuollossa ovat moninaiset, myös ennaltaehkäisevän terveydenhuollon näkökulmasta. Erilaisten menetelmien avulla on mahdollista poimia potilastietojärjestelmistä ja muista keskeisistä lähteistä rakenteista tai tekstimuotoista tietoa ja käsitellä sitä tekoälyä hyödyntäen siten, että aineistosta voidaan tunnistaa erilaisia riskitekijöitä ja laatia näiden riskitekijöiden avulla ennustemalleja. Tätä tietoa hyödyntämällä on mahdollista myös kehittää terveydenhuollon toimintaympäristössä toimintamalleja siten, että kansalaisten terveyttä voitaisiin tukea ja edistää jo varhaisemmassa vaiheessa. Tämä katsaus lisää tietoa tekoälyn hyödyntämismahdollisuuksista ennaltaehkäisevän terveydenhuollon näkökulmasta kuvaamalla, miten riskitekijöitä voidaan tunnistaa tekoälyä hyödyntämällä. Katsauksen perusteella aihe on kuitenkin vielä sen verran tuore, että parhaiden käytän-

töjen löytämiseksi tarvitaan vielä lisää tutkimusta, mutta jo saadut tulokset ovat tekoälyn hyödyntämismahdollisuuksien osalta hyvinkin lupaavia.

Lähteet

- [1] International Telecommunications Union. ITU and WHO launch new initiative to leverage power of Artificial Intelligence for Health. Geneva: International Telecommunications Union; 24 July 2018 [Viitattu: 15.10.2018]. Saatavissa: <https://www.itu.int/en/mediacentre/Pages/2018-pr18.aspx>.
- [2] European Commission. Artificial intelligence: Commission outlines a European approach to boost investment and set ethical guidelines. Brussels: European Commission; 25 April 2018 [Viitattu: 15.10.2018]. Saatavissa: http://europa.eu/rapid/press-release_IP-18-3362_en.htm.
- [3] International Telecommunications Union. Focus Group on "Artificial Intelligence for Health" International Telecommunications Union [Viitattu: 16.10.2018]. Saatavissa: <https://www.itu.int/en/ITU-T/focusgroups/ai4h/Pages/default.aspx>.
- [4] Resolution WHA71.7 Digital Health. In: Seventy-first World Health Assembly, Geneva 26 May 2018. Geneva: World Health Organization; 2018. [Viitattu 3.2.2019]. Saatavissa: http://apps.who.int/gb/ebwha/pdf_files/WHA71/A71_R7-en.pdf.
- [5] Valtioneuvosto. Älykäs robotiikka ja automaatio. Valtioneuvosto; 2016 [Viitattu: 15.10.2018]. Saatavissa: <https://valtioneuvosto.fi/paatokset/paatos?decisionId=0900908f804c7484>.
- [6] Sosiaali- ja terveysministeriö. Hyvinvoinnin AiRo-ohjelma. Sosiaali- ja terveysministeriö; 2018 [Viitattu: 16.10.2018]. Saatavissa: <http://urn.fi/URN:NBN:fi-fe2018082333957>.
- [7] Työ- ja elinkeinoministeriö. Suomen tekoälyaika. Suomi tekoälyn soveltamisen kärkimaaksi: Tavoite ja

- toimenpidesuosituksset. Työ- ja elinkeinoministeriön julkaisuja 41/2017. Työ- ja elinkeinoministeriö; 2017 [Viitattu: 15.10.2018]. Saatavissa: http://julkaisut.valtioneuvosto.fi/bitstream/handle/10024/80849/TEMrap_41_2017_Suomen_teko%C3%A4lyai ka.pdf.
- [8] Ailisto H, Neuvonen A, Nyman H, Halén M, Seppälä T (toim.). Tekoälyn kokonaiskuva ja kansallinen osaamiskartoitus – loppuraportti. Valtioneuvoston Selvitys- ja tutkimustoiminnan julkaisusarja 4/2019. Valtioneuvoston kanslia; 2019. [Viitattu 9.2.2019] Saatavissa: <http://urn.fi/URN:ISBN:978-952-287-632-4>
- [9] Tieteen termipankki. Tekoäly. Tieteen termipankki 12.5.2016 [Viitattu: 19.11.2018] Saatavissa: <http://tieteentermipankki.fi/wiki/Filosofia:teko%C3%A4ly>
- [10] MeSH, Medical Subject Headings 2018. Artificial Intelligence. [Viitattu: 23.11.2018]. Bethesda: National Institutes of Health, U.S. National Library of Medicine. Saatavissa: <https://meshb.nlm.nih.gov/record/ui?ui=D001185>.
- [11] Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism*. 2017 Apr;69S:S36-S40. <https://doi.org/10.1016/j.metabol.2017.01.011>
- [12] WHO. Noncommunicable Diseases Progress Monitor. Geneva: World Health Organisation; 2017. [viitattu 3.2.2019] Saatavissa: <https://apps.who.int/iris/bitstream/handle/10665/258940/9789241513029-eng.pdf?sequence=1>
- [13] Lappalainen K, Aminoff M, Hakulinen H, Hirvonen M, Räsänen K, Sauni R, Stengård J. Työterveys Suomessa vuonna 2015 ja kehitystrendi 2000-2015. Helsinki: Työterveyslaitos; 2016. [Viitattu 3.2.2019]. Saatavissa: <http://www.julkari.fi/handle/10024/131293>
- [14] Työterveyshuoltolaki 1383/2001. Sosiaali- ja terveysministeriö; 21.12.2001. Saatavissa: <https://www.finlex.fi/fi/laki/ajantasa/2001/20011383>.
- [15] Torracco RJ. Writing Integrative Literature Reviews: Guidelines and Examples. *Human Resource Development*. 2005;4(3):356–367. <https://doi.org/10.1177/1534484305278283>
- [16] Salminen A. Mikä kirjallisuuskatsaus? Johdatus kirjallisuuskatsauksen tyypeihin ja hallintotieteellisiin sovelluksiin. Vaasan yliopiston julkaisuja. Opetusjulkaisuja 62, Julkisjohtaminen 4. Vaasan yliopisto; 2011. [Viitattu 24.11.2018]. Saatavissa: https://www.univaasa.fi/materiaali/pdf/isbn_978-952-476-349-3.pdf.
- [17] Castro VM, Dligach D, Finan S, Yu S, Can A, Abd-El-Barr M ym. Large-scale identification of patients with cerebral aneurysms using natural language processing. *Neurology*. 2017 Jan 10;88(2):164-168. <https://doi.org/10.1212/WNL.0000000000003490>
- [18] Cruz AS, Lins HC, Medeiros RV, Filho JM, da Silva SG. Artificial intelligence on the identification of risk groups for osteoporosis, a general review. *Biomed Eng Online*. 2018 Jan 29;17(1):12. <https://doi.org/10.1186/s12938-018-0436-1>
- [19] Jackson RG, Patel R, Jayatilleke N, Kolliakou A, Ball M, Gorrell G ym. Natural language processing to extract symptoms of severe mental illness from clinical text: the Clinical Record Interactive Search Comprehensive Data Extraction (CRIS-CODE) project. *BMJ Open*. 2017 Jan 17;7(1):e012012. <https://doi.org/10.1136/bmjopen-2016-012012>
- [20] Tuarob S, Tucker CS, Kumara S, Giles CL, Pincus AL, Conroy DE, RAM N. How are you feeling? A personalized methodology for predicting mental states from temporally observable physical and behavioral information. *J Biomed Inform*. 2017 Apr;68:1-19. <https://doi.org/10.1016/j.jbi.2017.02.010>
- [21] Kim HC, Chun HW, Kim S, Coh BY, Kwon OJ, Moon YH. Longitudinal Study-Based Dementia Prediction for Public Health. *Int J Environ Res Public Health*. 2017 Aug 30;14(9). <https://doi.org/10.3390/ijerph14090983>
- [22] Ichikawa D, Sairo T, Ujita W, Oyama H. How can machine-learning methods assist in virtual screening for hyperuricemia? A healthcare machine-learning ap-

- proach. *J Biomed Inform.* 2016 Dec;64:20-24. <https://doi.org/10.1016/j.jbi.2016.09.012>
- [23] Jonnagoddala J, Liaw ST, Ray P, Kumar M, Dai HJ, Hsu CY. Identification and Progression of Heart Disease Risk Factors in Diabetic Patients from Longitudinal Electronic Health Records. *Biomed Res Int.* 2015;2015:636371. <https://doi.org/10.1155/2015/636371>
- [24] Singh P, Singh S, Pandi-Jain GS. Effective heart disease prediction system using data mining techniques. *Int J Nanomedicine.* 2018 Mar 15;13:121-124. <https://doi.org/10.2147/IJN.S124998>
- [25] Torii M, Fan JW, Yang WL, Lee T, Wiley MT, Zisook DS. Risk factor detection for heart disease by applying text analytics in electronic medical records. *J Biomed Inform.* 2015 Dec;58 Suppl:S164-70. <https://doi.org/10.1016/j.jbi.2015.08.011>
- [26] Liu RL, Tung SY, Lu YL. Extraction of disease factors from medical texts. *Applied Artificial Intelligence.* 2015;29(1):49-65. <https://doi.org/10.1080/08839514.2014.962281>
- [27] Ford E, Carroll JA, Smith HE, Scott D, Cassell JA. Extracting information from text of electronic medical records to improve case detection: a systematic review *J Am Med Inform Assoc.* 2016 Sep;23(5):1007-15. <https://doi.org/10.1093/jamia/ocv180>
- [28] Skeppstedt M, Kvist M, Nilsson GH, Dalianis H. Automatic recognition of disorders, findings, pharmaceuticals and body structures from clinical text: An annotation and machine learning study. *J Biomed Inform.* 2014 Jun;49:148-58. <https://doi.org/10.1016/j.jbi.2014.01.012>
- [29] Liddy ED. Natural Language Processing. In: *Encyclopedia of Library and Information Science.* 2nd Edition. New York: Marcel Decker Inc.; 2001 [Viitattu 19.11.2018] Saatavissa: <https://surface.syr.edu/cgi/viewcontent.cgi?article=1043&context=istpub>
- [30] Alpaydin E.. *Introduction to machine learning.* Third Edition. Cambridge: The MIT Press; 2014. (9780262325745 e-book).
- [31] The European Commission's High-Level Expert Group On Artificial Intelligence. Draft Ethics Guidelines for Trustworthy AI. European Commission. Brussels: European Commission; 18.12.2018 [Viitattu: 8.2.2019]. Saatavissa: https://ec.europa.eu/futurium/en/system/files/ged/ai_hleg_draft_ethics_guidelines_18_december.pdf
- [32] Tutkimuseettinen Neuvottelukunta. Hyvä tieteellinen käytäntö ja sen loukkausepäilyjen käsitteleminen Suomessa. Helsinki: Tutkimuseettinen Neuvottelukunta; 2013 [Viitattu 23.12.2018] Saatavissa: https://www.tenk.fi/sites/tenk.fi/files/HTK_ohje_2012.pdf.