



Vaasan yliopisto
UNIVERSITY OF VAASA

Maria Penttilä

Algoritmit monialaisen palveluntarpeen tunnistamisessa

Kuvaileva kirjallisuuskatsaus

Johtamisen akateeminen yksikkö
Pro gradu -tutkielma
Sosiaali- ja terveyshallintotiede

Vaasa 2022

VAASAN YLIOPISTO**Johtamisen akateeminen yksikkö**

Tekijä:	Maria Penttilä		
Tutkielman nimi:	Algoritmit monialaisen palveluntarpeen tunnistamisessa : kuvaileva kirjallisuuskatsaus		
Tutkinto:	Hallintotieteiden maisteri		
Oppiaine:	Sosiaali- ja terveyshallintotiede		
Työn ohjaaja:	Juha Lindell		
Valmistumisvuosi:	2022	Sivumäärä:	80

TIIVISTELMÄ:

Pienen väestöryhmän on todettu kerryttävän valtaosan julkisista sosiaali- ja terveydenhuollon kustannuksista. Tälle väestöryhmälle ei ole yhtä selittävää määritelmää. Kirjallisuudessa viitataan esimerkiksi paljon tai monialaisia palveluita tarvitseviin henkilöihin, jotka edellyttävät useamman erikoisalan osaamista. On kuitenkin havaittu, että Suomessa monia palveluita tarvitsevien henkilöiden tunnistaminen on puutteellista. Useissa terveyskeskuksissa ei ole vakiintuneita toimintatapoja monialaisen palveluntarpeen tunnistamiseksi. Kuitenkin varhainen hoitoon pääsy voi vähentää myöhäisempää palveluntarvetta ja siten myös julkisen sosiaali- ja terveydenhuollon kustannuksia. Palveluihin pääsy on myös inhimillinen kysymys.

Yhdeksi vaihtoehdoksi palveluihin pääsyn edistämiseksi on tarjottu tekoälypohjaista eli algoritmiperusteista palveluntarpeen tunnistamista. Koneoppimisalgoritmien avulla sähköisistä potilas- ja asiakastietokannoista saatavasta massadatasta voidaan poimia tietoja, joita voidaan käyttää henkilön palveluntarpeen tunnistamiseen ja ennakointiin. Aikaisemman kirjallisuuden perusteella, menetelmään liittyy kuitenkin huomattavia epävarmuustekijöitä, kuten etiikkaan ja tietosuojaan liittyviä kysymyksiä

Tässä sosiaali- ja terveyshallintotieteellisessä pro gradu -tutkielmassa kartoitetaan, miten algoritmeja on hyödynnetty monialaisen palveluntarpeen tunnistamisessa ja mitä etuja ja haittoja tähän liittyy. Tutkimusmetodina on kuvaileva kirjallisuuskatsaus. Aineisto on kerätty sähköisistä artikkelitietokannoista eksplisiittisesti. Tällöin aineiston haussa noudatetaan ennalta määriteltäviä hakukriteerejä. Menetelmä ei kuitenkaan ole verrannollinen systemaattiseen kirjallisuuskatsaukseen, vaan huomioitava on kuvailevan kirjallisuuskatsauksen metodinen väljyys ja subjektiivisuus. Lopullinen tutkimusaineisto koostuu 12 kansainvälisestä tutkimusartikkelista, jotka on analysoitu temaattisen analyysin keinoin.

Tulosten mukaan algoritmit ovat tunnistaneet ja ennakoineet monialaista palveluntarvetta niin lasten ja nuorten kuin myös ikäihmisten kohderyhmissä. Lisäksi algoritmit ovat tunnistaneet yhteiskunnallisesti kalliiksi luokiteltuja sairauksia. Diagnoosiryhmää tai potilaiden ikää määrittämättä, algoritmeja on hyödynnetty myös sellaisten monisairaiden potilaiden tunnistamiseksi, joilla katsottiin olevan korkea riski kasvavalle ja kalliille palveluntarpeelle tulevaisuudessa. Etuihin ja haittoihin liittyvinä teemoina on tunnistettu mm. algoritmien kyky edistää terveydenhuollon resurssien käyttöä mutta myös se, että monet monialaisen palveluntarpeen tunnistamisen malleista olivat vasta kokeilu- ja kehittämisasteella. Tulosten perusteella on pääteltävissä, että algoritmiperusteiseen palveluntarpeen tunnistamiseen liittyy potentiaalia, mutta myös avoimia kysymyksiä. Yhdeksi jatkotutkimuskohteeksi ehdotetaan selvitystä siitä, mikä ero mahdollisesti suurilla tekoälyinvestoinneilla olisi verrattuna siihen, että tulevilla hyvinvointialueilla otettaisiin käyttöön muita rutiininomaisia ja systemaattisia monialaisen palveluntarpeen tunnistamisen keinoja.

AVAINSANAT: sote-palvelut, algoritmit, tunnistaminen, profilointi, ennakointi

Sisällys

1	Johdanto	6
1.1	Tekoäly palveluntarpeen tunnistajana	7
1.2	Tutkimustehtävä ja tutkimuskysymykset	8
2	Algoritmit sosiaali- ja terveystalvveluissa	10
2.1	Massadata algoritmien polttoaineena	11
2.2	Aikaisempi kirjallisuus tekoälyperusteisesta sairauksien ja palveluntarpeen tunnistamisesta	12
2.3	Laillisuusnäkökulma algoritmien suorittamaan palveluntarpeen tunnistamiseen	15
2.4	Algoritmien hyödyntämiseen liittyviä jännitteitä	17
2.5	Yhteenveto käytettävistä tekoälyn käsitteistä	19
3	Monialainen palveluntarve sosiaali- ja terveystalvveluissa	21
3.1	Käsitteellisiä lähestymistapoja palveluntarpeen määrittelyyn	22
3.1.1	Paljonko ja mitä palveluita?	22
3.1.2	Kompleksisuus huomioi tarpeiden yhteen kietoutumisen	24
3.1.3	Yhteisasiakkuus palveluntarpeen määrittelyssä	25
3.1.4	Tämän tutkielman käsitteelliset valinnat	26
3.2	Monialaisen palveluntarpeen tunnistamisen nykytila	27
3.2.1	Aikaisempi kirjallisuus profiloinnista ja digitalisaatiosta osana monialaisen palveluntarpeen tunnistamista	31
3.2.2	Nykytilan haasteet – yhteenveto monialaisen palveluntarpeen tunnistamisesta	34
4	Tutkimusmenetelmän kuvaileva kirjallisuuskatsaus	36
4.1	Erytispirteet osana tutkimusprosessia	38
4.1.1	Kuvailevan kirjallisuuskatsauksen argumentaatio	39
4.1.2	Eettiset periaatteet	41
4.2	Tutkimusprosessin kuvaus	42

4.2.1	Aineiston keruu	44
4.2.2	Aineiston valinta	46
4.2.3	Aineiston analyysi	47
5	Tulokset	50
5.1	Miten algoritmeja on hyödynnetty monialaisen palveluntarpeen tunnistamisessa?	50
5.2	Algoritmiperusteisen palveluntarpeen tunnistamisen edut ja haitat	53
6	Yhteenveto ja tulkinta	58
	Lähteet	65
	Liitteet	77
	Liite 1. Hakupäiväkirja	77
	Liite 2. Kuvailevan kirjallisuuskatsauksen tutkimusaineisto	78

Kuviot

Kuvio 1.	Tutkielman teknologisten käsitteiden jäsentyminen.	20
Kuvio 2.	Monialaisen palveluntarpeen määrittely tässä tutkielmassa.	27
Kuvio 3.	Temaattinen kartta	57

Taulukot

Taulukko 1.	Palveluntarpeen tunnistamisen mallit Kivipelto ym. (2019) mukaillen.	30
Taulukko 2.	Kirjallisuuskatsauksien vertailua (Gregory ja Denniss, 2018).	38
Taulukko 3.	Käytetyt hakusanat.	45
Taulukko 4.	Valintakriteerit.	46
Taulukko 5.	Aineiston koodaus eli ryhmittely.	49

1 Johdanto

Tekoälyn odotetaan lisäävän julkisten palvelujen yhdenmukaisuutta ja tehokkuutta (Autioniemi, 2021, s. 139; Parviainen & Rantala, 2020, s. 1–2). Tekoäly on laaja käsite, johon liittyviä termejä käytetään laajasti ja toisinaan myös synonyymeina (Kuziemski & Misuraca, 2020, s. 2). Yhdellä tapaa määriteltynä, tekoälyn avulla tietokoneet voivat suorittaa ihmisälykkyyttä vaativia tehtäviä (Lexico, 2022a). Karkeasti kuvattuna tekoälyyn pohjautuvat järjestelmät oppivat esimerkiksi koneoppiseen ja syväoppimiseen perustuvien tekniikoiden avulla (Panch ja muut 2018, s. 1–2).

Pääministeri Marinin hallitusohjelmaan (Valtioneuvosto, 2019, s. 107–109, s. ja 161) kirjatut tavoitteet ja näiden toimeenpanemiseksi perustetut ohjelmat tähtäävät digitalisaation ja tekoälyn hyödyntämiseen yli hallinto- ja toimialarajojen. Hyötyjä tavoitellaan myös varhaisen palveluntarpeen tunnistamisen ja eri viranomais- ja hallinnonalojen yhteisasiakkuuksiin liittyen. Tavoitetta voidaan pitää tärkeänä: arviolta noin 10 % väestöstä kerryttää 90 % sosiaali- ja terveystalvelujen kustannuksista (Berk & Monheit, 2001; Garfinkel ja muut, 1988, s. 41; Kapiainen ja muut 2010, s. 4; Leskelä ja muut, 2013, s. 3163). Tälle väestöryhmälle ei ole yhtä selittävää määritelmää: puhutaan yhteisasiakkaista, paljon tai kalliita palveluita tarvitsevista sekä monialaisen palveluntarpeen omaavista henkilöistä. Henkilöllä on asiakkuus esimerkiksi usean eri terveyskeskuksen, poliklinikan ja sosiaalihuollon kanssa. Kyseessä ei ole massa, vaan joukko yksilöitä ja eri elämäntilanteita. (Hujala & Lammintakanen, 2018, s. 16–18)

Kivipelto ja muut (2019, s. 5) kuvaavat, kuinka kansallisesti ja kansainvälisesti palveluita on jo vuosia pyritty kehittämään siten, että henkilön palveluntarve tunnistettaisiin mahdollisimman varhain. Nopea pääsy palveluihin voi vähentää myöhemmin ilmenevää palveluntarvetta, edistää työkykyä ja parantaa sosiaali- ja terveydenhuollon palvelujen tehokkuutta ja sujuvuutta. Koiviston ja Tiiringin (2020, s. 97–98) mukaan, Suomessa palveluntarpeen tunnistamiseen ja ennakointiin on kehitetty useita toimintamalleja, mutta valtaosassa organisaatioita ei ole sovitusti käytössä mitään tunnistamisen

työkalua. Tunnistaminen on kuitenkin olennaista, jotta asiakas voidaan ohjata hänen tarpeitaan vastaaviin palveluihin. Valtiontalouden tarkastusviraston selvityksessä (VTV, 2017) tuotiin esille myös palveluntarpeen tunnistamisen kansantaloudellinen merkitys. Mikäli esimerkiksi terveydentilan muutoksiin ei reagoita riittävän varhain, henkilön riski kalliimmille sosiaali- ja terveyspalveluille, kuten erikoissairaanhoidolle, kasvaa. Tämä puolestaan johtaa kustannusten lisääntymiseen. Edellä kuvatun kansantaloudellisen tulokulman lisäksi voidaan todeta, että palveluntarpeen tunnistaminen on myös inhimillinen kysymys.

1.1 Tekoäly palveluntarpeen tunnistajana

Yhdeksi vaihtoehdoksi hoidon organisoimiseksi on tarjottu tekoälypohjaista eli algoritmiperusteista sairauksien ja palvelutarpeiden tunnistamista potilas- ja asiakasrekistereistä saatavien tietojen avulla (Kivipelto ja muut, 2019, s. 8; Koivisto & Tiirinki, 2020, s. 98). Algoritmillä tarkoitetaan ohjetta tai kuvausta, jota tietokone käyttää laskennassa tai ongelmanratkaisussa (Lexico, 2022b). Algoritmit voidaan ohjelmoida tunnistamaan potilas- ja asiakasrekistereistä sairauksia tai riskitekijöitä, jotka ennakoivat palveluntarvetta (Zhou ja muut, 2014, s. 18–19). Varhaisia uutisia algoritmiperusteisesta palveluntarpeen tunnistamisesta on myös Suomessa, esimerkiksi lastensuojelun asiakkuutta ennakoivan hankkeen myötä (Yle 2018; ks. myös Parviainen & Rantala 2020, s. 2–3).

Algoritmien hyödyntämiseen sosiaali- ja terveyspalveluissa liittyy kuitenkin useita teknisiä sekä eettisiä rajoitteita mm. yksityisyyteen liittyvissä kysymyksissä (Ngiam & Khor, 2019, s. 271). Terveydentilaan liittyvien ominaisuuksien arviointi ja ennakointi on profiloitua, johon on otettu kantaa myös lainsäädännössä (ks. esim. EU:n yleinen tietosuoja-asetus 2016/679). Algoritmit voivat tehdä myös virheellisiä päätelmiä (Strang & Sun 2020, s. 990–996). Monialaisen palveluntarpeen kontekstissa on esitetty, ettei pelkkä tunnistaminen ole tae henkilön ongelmien ratkaisusta, vaan huomio tulee

kiinnittää koko palveluketjuun (Koivisto ja Tiirinki, 2020, s. 98). On myös arvioitu, että terveydenhuollon digitalisaation hyötyjä on ylipäättään liioiteltu (Jones ja muut, 2012, s. 2243–2245).

1.2 Tutkimustehtävä ja tutkimuskysymykset

Tämän tutkielman tehtävänä on kuvailevan kirjallisuuskatsauksen avulla selvittää, miten algoritmiperusteista palveluntarpeen tunnistamista (myöh. myös *algoritmiperusteista profilointia*) voidaan hyödyntää monialaisen palveluntarpeen tunnistamisessa sosiaali- ja terveyspalveluissa. Tarkoituksena on antaa yleiskuva siitä, miten algoritmit voivat tunnistaa ja ennakoida monialaista palveluntarvetta. Perusteet tutkielman toteuttamiselle nojautuvat aiheen kansantaloudelliseen ja inhimilliseen merkittävyyteen. Toisaalta tekoälyyn terveydenhuollossa liittyy suuria odotuksia, vaikka sen hyödyntämiseen liittyy myös huomattavaa epävarmuutta. Yhtenä tutkielman tavoitteena onkin luoda pohjaa mahdollisille jatkotutkimuskohteille.

Tutkielman rakenne on seuraavanlainen. Alussa kuvataan algoritmien ja niiden avulla tapahtuvan palveluntarpeen tunnistamisen aikaisempi tietoperusta. Kuitenkin algoritmiperusteisen palveluntarpeen tunnistamisen tekninen toteutus ja tekniset toimintaperiaatteet on rajattu pois, sillä kyseessä ei ole tietojenkäsittelytieteellinen pro gradu -tutkielma. Tämän jälkeen kuvataan viitekehys monialaiselle palveluntarpeelle ja sen tunnistamiselle. Käsitteellisessä jäsentämisessä hyödynnetään kansainvälisiä lähteitä, mutta palveluntarpeen tunnistamista käsitellään suomalaisen sosiaali- ja terveyspalvelujärjestelmän kontekstissa. Tutkielman luku 4 esittelee kuvailevan kirjallisuuskatsauksen menetelmänä, jonka jälkeen vastataan tutkimuskysymyksiin:

- 1) Miten algoritmeja on hyödynnetty monialaisen palveluntarpeen tunnistamisessa?
- 2) Mitä etuja ja haittoja algoritmiperusteisessa palveluntarpeen tunnistamisessa on?

Tutkielman lopussa kuvataan tulokset ja niistä muodostetut keskeiset johtopäätökset. Tutkielman lopputulos voi antaa käsityksen siitä, miten algoritmiperusteisen palveluntarpeen tunnistamisen avulla voidaan vastata yhteen sosiaali- ja terveyspalvelujen haasteeseen ja vaikuttaa monia palveluja tarvitsevien asiakkaiden palveluihin pääsemiseen. Onnistuessaan tutkielma voi lisätä ymmärrystä toimintamalliin liittyvistä hyödyistä ja haitoista sekä tarvittavista jatkotutkimuskohteista.

Miten perustella hallintotieteen roolia tässä tekoälyyn liittyvässä tutkielmassa? Hallintotieteellisen tutkimuksen perusluonne on poikkitieteellinen, johon sosiaali- ja terveyshallintotiede tuo mukaan oman alansa substanssin (Niiranen & Lammintakanen, 2011, s. 113, 133). Lisäksi teknologia on kuvattu hallinnan tapana, ja teknisten ratkaisujen avulla myös säännellään ja ohjataan kansalaisten toimintaa (Parviainen & Rantala, 2020, s. 7–8). Autioniemi (2021, s. 141–155) nimeää hallintotieteen kiinnostukseksi palveluiden tuottamisen mahdollisimman taloudellisella ja tehokkaalla tavalla. Tekoälyn tarkastelu vain taloudellisesta näkökulmasta ei kuitenkaan sovellu julkisiin palveluihin, jossa kohdattavana on lisäksi eettiset ja poliittiset kysymykset. Myös liian positiivisilta odotuksilta on pitäydyttävä, varsinkin tutkimusta tehtäessä. Edellä kuvattu tukee siten myös tämän tutkielman tavoitetta sekä kysymyksenasettelua siitä, millaisia etuja ja haittoja algoritmiperusteisessa profiloinnissa näyttäisi olevan. Myös tutkimus tekoälyn soveltamisesta julkishallinnossa ja julkisissa palveluissa on vasta aluillaan (Autioniemi 2020, s. 5), mikä luo tarpeen tälle yleiskatsaukselliselle tutkielmalle sekä jatkotutkimuskohteiden arvioinnille. Saatuja tutkimustuloksia tulee kuitenkin tarkastella kriittisesti – käytetty kuvailevan kirjallisuuskatsauksen menetelmä auttaa ajantasaistamaan saatavilla olevaa tietoa (Salminen, 2011, s. 7), mutta tulosten hyödyntäminen laajemmassa poliittisessa päätöksenteossa ei ole mahdollista (Green ja muut, 2006, s. 104; ks. myös Salminen, 2011, s. 7). Tutkielman tarkoituksena ei ole antaa toimintasuositusta tai ohjeistusta päätöksenteon tueksi.

2 Algoritmit sosiaali- ja terveystalveluissa

Muihin EU-maihin verrattuna, Suomi on kärjessä julkishallinnon digitaalisissa palveluissa ja Suomella on johtoasema digitalisaatiossa (Mäntylä ja muut, 2022, s. 118; DESI-indeksin mukaan). Vuonna 1996 Suomi julkaisi ensimmäisten joukossa Euroopassa kansallisen strategian tietotekniikan hyödyntämiseen sosiaali- ja terveydenhuollossa (Saranto ja muut, 2020, s. 181). Stenvallin ja Virtasen (2021, s. 129–131) mukaan, digitalisaatiosta itsessään on tullut yksi vahvimmista muutosajureista viimeisen kymmenen vuoden aikana. Aluksi digitalisaatio oli eri toiminnoissa tiettyjen osien korvaaja, jonka myötä palvelut tehostuivat ja sujuvoituivat. Tällöin digitalisaatiota hyödynnettiin olemassa olevien käytänteiden rinnalla. Kuitenkin nykyään toiminta on rakennettu digitaalisten toimintamallien varaan, ja kehittäminen on yhä teknologialähtoisempää. Tekoäly on tämän kehityksen seuraava askel. On sanottu, että tekoälyn vallankumous tulee voimistumaan seuraavan 20-vuoden aikana ja sen uskotaan vaikuttavan yhteiskuntaan vielä merkittävämmällä tavalla kuin teollisen tai digitaalisen vallankumouksen (Makridakis, 2017, s. 59).

Käsitteellisesti ei ole aina selvää, mitä tekoälyllä tarkoitetaan. Amerikkalaisen tutkija Larry Teslerin (1970) ajatusten pohjalta on levinnyt siteeraus, jonka mukaan tekoäly on sitä, mitä ei ole vielä keksitty. Toisella tapaa määriteltynä tekoäly on prosessi, jonka avulla tietokoneet voivat suorittaa ihmisälykkyyttä vaativia tehtäviä (Lexico, 2022a). Esimerkiksi koneoppiminen sekä syväoppiminen ovat teknisiä tapoja tekoälyn toteuttamiseen (Panch ja muut, 2018, s. 1–2). Koneoppiminen on myös datan prosessointityökalu terveydenhuollossa (Ngiam & Khor, 2019, s. 262). Nimenomaan koneoppimiseen pohjautuvan tekoälyn kehittämisen algoritmin eli matemaattisloogisen mallin avulla voidaan esimerkiksi potilastietoaaineiston perusteella analysoida, käsitellä, ennustaa, ohjata sekä tehdä tulkintoja henkilön terveydentilasta (Ferdous ja muut, 2020). Vastaavasti syväoppimiseen pohjautuvat järjestelmät luovat neuroverkkomalleja, joiden avulla voidaan käsitellä dataa ja luoda täsmääviä, aineistoon perustuvia päätöksiä (Kelleher, 2020, s. 7–16). Ngiam ja Khor (2019, s. 264) kuvaavat, kuinka syväoppimista

pidetään usein ylivoimaisena muihin tekoälymalleihin verrattuna, sillä syväoppiminen kykenee käsittelemään valtavasti erilaista dataa. Terveystieteiden tutkimuksessa käytettävään tekoälyyn soveltuvat kuitenkin myös muut mallit kone- ja syväoppimisen lisäksi.

2.1 Massadata algoritmien polttoaineena

Toteutustavasta riippumatta, tekoäly tarvitsee toimiakseen massadataa eli *big dataa*. Tällä viitataan eri lähteistä saatavaan, laajaan tiedon määrään, jota voidaan analysoida laskennallisesti ja josta voidaan muodostaa trendejä erityisesti ihmisen käyttäytymiseen ja toimintaan liittyen (Lexico, 2022b). Parviainen ja Rantalan (2020, s. 1–2) kirjoittavat lisääntyneestä ennakoivasta analytiikasta, jossa massadataa hyödyntävien koneoppimisalgoritmien avulla voidaan luoda ennusteita ja malleja.

Gandomin ja Haiderin (2015, s. 137) mukaan massadataa kuvataan usein sen koon perusteella. Määrän ja koon käsite on kuitenkin suhteellinen: se mikä on big dataa tänään, ei välttämättä ole sitä enää huomenna, sillä myös mahdollisuudet säilöä ja varastoida entistä isompaa dataa kehittyvät koko ajan. Vakiintunut ja kuvaavampi käsitteellinen viitekehys, johon myös Gandomi ja Haider (2015) nojautuvat, on kuvata massadataa sen kolmen ominaisuuden avulla. Näitä ovat volyyymi, monimuotoisuus ja nopeus (volume, variety, velocity). Emani ja muut (2015, s. 71) täydentävät kuvausta toteamalla, että monet instituutiot nimeävät massadatan ominaisuuksiksi myös arvon ja luotettavuuden (value, veracity). Massadataa koskevat määritelmät ovatkin myös toimialakohtaisia (Gandomi & Haider, 2015, s. 138-139). Erityisesti terveydenhuollossa luotettavuus massadatan ominaisuutena korostuu, etiikan ja yksityisyyden merkityksien vuoksi (Strang & Sun, 2020, s. 995).

Sosiaali- ja terveydenhuollossa hyödynnettävissä oleva massadata on peräisin mitä erilaisimmista lähteistä. Sähköisten asiakas- ja potilastietojärjestelmien lisäksi dataa voidaan kerätä laboratoriokokeista, lääkärin omista muistiinpanoista,

kuvantamistuloksista, apteekeista, resepteistä, vakuutusyhtiöiden tiedoista, erilaisista terveydentilaa mittaavista sensori- ja monitorointijärjestelmistä, jopa sosiaalisen median postauksista. (Ragupathi & Ragupathi, 2014, s. 1–2, s. 10) Syvä- ja koneoppimisen avulla luotu algoritmi yhdistettynä massadataan on työkalu, jonka katsotaan voivan edistää terveydenhuollon tehokkuutta ja kustannusvaikuttavuutta (Ngiam & Khor, 2019, s. 271). Massadatasta kerättävä tieto mahdollistaa sairauksien toteamisen varhaisemmassa vaiheessa sekä tietyn yksilön tai väestöryhmän terveydentilan seurannan tehokkaasti ja vaikuttavasti. Massadatasta saatujen yhteneväisyyksien ja niistä muodostettujen kokonaisuuksien avulla voidaan parantaa hoitoa, alentaa kustannuksia ja jopa pelastaa elämiä. (Ragupathi & Ragupathi, 2014, s. 1–2, s. 10)

2.2 Aikaisempi kirjallisuus tekoälyperusteisesta sairauksien ja palveluntarpeen tunnistamisesta

Lääketieteessä koneoppimisalgoritmien hyöty sairauksien ennakoinnissa on todettu kiistattomaksi (Ferdous ja muut, 2020). Tutkimuskirjallisuudessa eniten edustettuna hyödyntämisalueena on radiologia (Panch ja muut 2018, s. 4). Esimerkiksi Stanfordin yliopiston tutkimuksessa tekoälyperusteinen algoritmi tunnisti keuhkokuumeen röntgenkuvien perusteella automatisoidusti ja jopa paremmin, kuin ammattiradiologit (Rajpurkar ja muut, 2017). Toinen keskeinen hyödyntämisa-alue on sydän- ja verenkiertoelimistön sairaudet. Euroopan kardiologiyhdistyksen toteuttamassa tutkimuksessa kehitettiin, ohjelmoitiin ja validoitiin algoritmi ennakoimaan henkilön riskiä sairastua sydän- ja verenkiertoelimistön sairauteen seuraavan 10 vuoden kuluessa. Tutkimusaineistoa kerättiin 15 eri Euroopan maasta. Aineistossa oli mukana lähes 680 000 iältään 40-69 -vuotiasta henkilöä, joilla ei ollut aikaisempia sydän- ja verenkiertoelimistön sairauksia tai diabetesta. Tutkimuksen mukaan eurooppalaiselle väestölle ja sairaanhoidolle kustomoitu algoritmi auttaa parantamaan niiden henkilöiden tunnistamista, joilla on korkeampi riski sairastua sydän- ja

verenkiertoelimistön sairauksiin. Tutkimusryhmään osallistui myös Suomesta Terveystieteiden ja hyvinvoinnin laitoksen tutkijoita. (European Society of Cardiology, 2021, s. 2440-2451; THL, 2021c)

Käytännössä algoritmeja voidaan hyödyntää yhä useamman sairauden tunnistamisessa ja ennakoinnissa. Ferdous työryhmineen (2020) löysi tutkimuskirjallisuuden perusteella 17 erilaista algoritmia, jotka ennakoivat 13 eri sairautta. Algoritmit ennakoivat mm. maksa- ja sydänsairauksia, rintasyöpää, diabetesta, kilpirauhasen vajaatoimintaa, Alzheimerin tautia, munuaissairauksia sekä korvasairauksia. Ferdous työryhmineen jopa luokitteli algoritmit paremmuusjärjestykseen niiden diagnostisen tarkkuuden perusteella. He kuitenkin huomauttivat, että algoritmit eivät olleet aukottoman luotettavia.

Algoritmien avulla on myös pyritty paikantamaan sairauksien ilmentymistä alueellisesti. Kanadalaisessa tutkimuksessa algoritmit tunnistivat alueellisen terveystieteiden rekisteristä ICD-luokituksen mukaisia sairauksia tai sairauksien puuttumista. Terveystieteiden rekisteri piti sisällään tietoja postinumeroista sekä yli 65-vuotiaiden lääkitystiedoista sekä laboratoriotuloksista. Tutkimuksessa algoritmit tunnistivat 30 erilaista sairautta, mm. astmaa, nivelrikkoa, syöpä- sekä munuais- ja sydänsairauksia. Myös kroonisia suolistosairauksia sekä MS-tautia esiintyi, samoin skitsofreniaa ja alkoholin liikakäyttöön liittyviä ongelmia. Noin yksi neljästä ihmisestä tunnistettiin tutkimuksen määrittelemänä monisairaaksi, eli kahden tai useamman diagnoosin omaavaksi. Algoritmien hyödyntämisen katsottiin mahdollistavan uudenlaisen lähestymistavan monia sairauksia omaavien henkilöiden tunnistamiseen. (Tonelli ja muut, 2015, s. 1–11; ks. myös Kivipelto ja muut, 2019, s. 8)

Koivisto ja muut (2019, s. 10) viittaavat myös Gillinghamin (2016) Uudessa-Seelannissa tekemään tutkimukseen, jossa lastensuojelun riskiasiakkaita tunnistettiin sosiaalityössä algoritmien avulla. Tarkoituksena oli löytää tapoja suuressa lastensuojelun riskissä olevien lasten interventioiden tukemiseksi. Työryhmä kehitti algoritmin, joka tunnisti

lastensuojeliasiakkaiden haasteellisiin tilanteisiin liittyviä riskitekijöitä. Haasteellisiksi tilanteiksi määriteltiin esimerkiksi kaltoinkohtelu tai fyysisten tarpeiden laiminlyönti. Tulosten mukaan algoritmin avulla olisi mahdollista ennakoita tulevia kaltoinkohtelutapauksia. Malli katsottiin toimivaksi myös muilla sosiaalityön alueilla. Kuitenkin parhaimman lopputuloksen saamiseksi, mallilla käyttöön suositellaan yhdistettävän varhaisen puuttumisen mallit.

Koiviston ja muiden (2019) toteuttaman kirjallisuuskatsauksen lisäksi, suomenkielinen tutkimuskirjallisuus tekoälyperusteisesta palveluntarpeen tunnistamisesta näyttää tämän tutkielman aineistonhaun perusteella vähäiseltä. Finna-tiedonhakupalvelusta ei tutkielman kirjoitushetkellä löytynyt yhtään julkaisua hakusanoin 'monialainen palveluntarve' AND 'tekoäly'. Hakusanoin 'terveydenhuolto' ja 'profilointi' osumia syntyi kaksi (2), joista kumpikaan ei kuitenkaan vaikuttanut relevantilta suhteessa tähän tutkielmaan. Haun laajentuessa mihin tahansa tekoälyyn ja terveydenhuoltoon liittyvään ('tekoäly' OR 'terveydenhuolto'), osumia on tuhansia, mutta niiden relevanttius tämän tutkielman kanssa on kyseenalainen. Tähän arvioon toki saattaa vaikuttaa aikaisemmin todettu tekoälyyn liittyvä käsitteellisen jäsentymättömyys – tämän puitteissa voi olla mahdollista, että mukana on myös tutkielman kannalta relevantteja tutkimuksia, mutta eri käsittein.

Kuitenkin myös suomalaisissa sosiaali- ja terveystalveissa on sovellettu algoritmeja palveluntarpeen tunnistamiseen ja ennakointiin, vaikka tosiasiallinen käyttö näyttäytyykin vielä vähäisenä. Yksi uutisoinneista (Yle, 2018; Parviainen & Rantala 2020, s. 2–3) on Espoon kaupungin kokeilu, jossa tekoäly seuroi massadatatista riskitekijöitä, jotka ilmetessään yhdenaikaisesti samalla henkilöllä voivat laukaista raskaiden tai kalliiden palveluiden, kuten lastensuojelun, tarpeen. Alustavien tulosten perusteella, tekoäly tunnistasi avun tarvitsijoita ja löysi noin 280 tekijää, jotka ennakoivat lastensuojelun asiakkuutta. Lisäksi eräs Suomessa käytetty ja ennakointia hyödyntävä terveystalve on Omaolo, joka antaa käyttäjälleen hänen terveydentilaansa sopivia, henkilökohtaisia ja ajantasaisimpaan tieteelliseen näyttöön perustuvia ohjeita

(Omaolo.fi; Parviainen & Rantala 2020, s. 2–3). Myös Nordic Healthcare Group Oy ja Raisoft Oy ovat kehittäneet RAI-järjestelmään yhteensopivan riskityökalun, joka tunnistaa kotihoidon asiakkaista ne, joilla on kohonnut riski joutua ympärivuorokautiseen hoitoon (Raisoft Oy). Terveyden ja hyvinvoinnin laitos (2022b) kuvaa RAI-järjestelmän potilastiedon keruuseen ja seulontaan suunniteltuna ohjelmana, joka tukee asiakas- ja palvelusuunnitelman laatimista sosiaali- ja terveystalveissa. Lakiin ikääntyneen väestön toimintakyvyn tukemisesta sekä iäkkäiden sosiaali- ja terveystalveista (980/2012) on kirjattu velvoite, jonka mukaan kuntien tulee käyttää iäkkään asiakkaan palveluntarpeen ja toimintakyvyn arviointiin RAI-arviointivälineistöä.

Terveyden ja hyvinvoinnin laitoksen, Lapin yliopiston, Teknologian tutkimuskeskus VTT Oy:n ja Helsingin yliopiston yhteistyönä käynnissä on kansallinen MAITE-kehittämispilotti, jossa monialaista palvelutarvetta ennakoidaan tekoälyn avulla ikäihmisten asiakasryhmässä. Hanke on sosiaali- ja terveysministeriön rahoittama ja sen osa-alueina ovat mm. ennakoinnin organisatorinen kehittäminen, tekoälypohjaisen ennustemallin kehittäminen, tekoälypohjaisen ennustemallin realisoinnin ohjelmistoteknisen kehyksen kehittäminen ja ennustetiedon hyödyntämisen mahdollisuudet nykyainsäädännön puitteissa. Hankkeen on tarkoitus päättyä kesäkuussa 2023. (Innokylä, 2022)

2.3 Laillisuusnäkökulma algoritmien suorittamaan palveluntarpeen tunnistamiseen

Laillisuusnäkökulmasta tekoälyperusteinen potilastietojen ennakointi on algoritmiperusteista profilointia. EU:n yleisen tietosuojasetuksen (2016/679) tulkinnassa EU:n tietosuojaryhmä (2016, s. 7–9) on määrittänyt, että profiloinnilla tarkoitetaan henkilötietojen käsittelyä, jonka tavoitteena on arvioida henkilön ominaisuuksia sekä analysoida tai ennakoita henkilön toimintaa työsuoritukseen, terveyteen, mieltymyksiin, käyttäytymiseen, sijaintiin tai liikkeisiin liittyen. Lähtökohtaisesti profilointi on automatisoitua käsittelyä. Profilointi suoritetaan

henkilötiedoilla erilaisten tilastollisten päätelmien avulla, ja sen tavoitteena on luonnollisen henkilön henkilökohtaisten ominaisuuksien arvioiminen ja heitä koskevien ennusteiden tekeminen. Vastaavasti henkilöiden kategorisointi heidän ominaisuuksiensa, kuten iän, sukupuolen tai fyysisten piirteiden perusteella, ei automaattisesti täytä profiloinnin määritelmää. Painoarvoa annetaan sille, mikä on luokittelun tavoite: päätelmien ja ennusteiden tekeminen on profilointia, yrityksen asiakkaiden luokittelu iän tai sukupuolen mukaan kokonaiskuvan muodostamiseksi ei ole profilointia. Yleisesti profilointi merkitsee henkilöiden tai ryhmien tietojen kokoamista, jonka perusteella henkilö(t) luokitellaan ominaisuuksien tai käyttäytymismallien analysoimiseksi tai ennustamiseksi. (Euroopan unionin tietosuojatyöryhmä, 2017, s. 8–9)

Suomalaisessa hallintoympäristössä jo vuosia hyödynnetty sääntöpohjaista automaattista päätöksentekoa, jolloin asiassa sovellettavat normit on muutettu kyllä/ei-säännöiksi ja joiden perusteella tietojärjestelmä tuottaa päätöksen (Oikeusministeriö, 2020, s. 14). Automatisoitu päätöksentekoa tarkoittaa tekoälyn tekemää päätöksentekoa ilman ihmisen osallistumista. Tällöin kyse ei ole profiloinnista, mutta automaattista päätöksentekoa voidaan hyödyntää profiloinnin ja sen tulosten käsittelyn yhteydessä. Esimerkiksi ylinopeussakot voidaan määrätä automatisoidusti nopeudenvälvontakameroiden avulla, mutta tähän ei liity profilointia. Mikäli kuljettajan liikenne- ja ajokäyttäytymistä tarkasteltaisiin tietyltä aikaväliltä ja sakkorangaistuksen määräytymiseen vaikuttaisivat myös muut tekijät, muuttuisi tulkinta profiloinniksi. Profilointiin perustuvassa päätöksenteossa, johon ei sisälly automaattista päätöksentekoa, ihminen tekee lopullisen päätöksen profiloinnista saamansa tiedon perusteella. Täysin profilointiin perustuvassa automaattisessa päätöksenteossa, algoritmi tekee itsenäisen päätöksen ja päätös toimitetaan asianomaiselle, ilman virkailijan suorittamaa harkintaa. (Euroopan unionin tietosuojatyöryhmä, 2017, s. 8–9)

Algoritmiperusteista profilointia ohjaavaa keskeistä lainsäädäntöä on Euroopan parlamentin ja neuvoston yleisessä tietosuoja-asetuksessa (2016/679), jossa otetaan kantaa myös automaattiseen päätöksentekoon. Asetuksen artikla 22 säätelee, kuinka

henkilöllä on oikeus olla joutumatta automaattisesti laaditun päätöksen tai profiloinnin kohteeksi tilanteessa, jossa päätöksellä on häneen oikeudellisia tai muita merkittäviä vaikutuksia. Edellä kuvatun soveltamisesta on säädetty poikkeuksin. Automaattista päätöksentekoa ja profilointia voidaan soveltaa, mikäli menettelytapa on hyväksytty EU-jäsenvaltion lainsäädännössä. Lainsäädännössä tulee kuitenkin olla vahvistettuna menettelytavat, jotka varmentavat henkilön oikeusturvan, vapaudet ja edun. Henkilön tulee myös antaa tietoinen suostumus automaattisesta päätöksenteosta ja profiloinnista. EU:n tietosuoja-asetus säätelee myös tietojen luovuttamisesta. (Euroopan unionin tietosuojatyöryhmä, 2017, s. 22–26) Tämän lisäksi erityisesti sosiaali- ja terveydenhuollossa tulee huomioitavaksi myös muuta henkilötietojen käsittelyyn liittyvää lainsäädäntöä, kuten laki potilaan asemasta ja oikeuksista (785/1992) sekä laki sosiaali- ja terveydenhuollon asiakastietojen sähköisestä käsittelystä (784/2021).

Voidaan todeta, että Suomessa niin automaattista päätöksentekoa kuin algoritmiperusteista profilointia ohjaava lainsäädäntö on monelta osin vasta kehitteillä. Asiassa sovellettava lainsäädäntö on puutteellinen virkavastuun ja vahingonkorvausoikeuden näkökulmasta (Mäntylä ja muut, 2022, s. 142). Myös eduskunnan apulaisoikeusasiamies (EOAK/3379/2018) ja Perustuslakivaliokunta (PeVL 78/2018 vp, ks. myös PeVL 62/2018) ovat kannanotoissaan todenneet automaattisen päätöksenteon lainvastaiseksi ja puutteelliseksi muun muassa hyvän hallinnon vaatimusten osalta, jotka on säädetty Hallintolain luvussa 2 ja turvattu Perustuslain 2. luvun 21 §:ssä. Tutkielman kirjoitushetkellä oikeusministeriössä (2022) on valmisteilla lakimuutos, joka kattaa hallintoasian automaattisen ratkaisemisen mahdollistavan sääntelyn.

2.4 Algoritmien hyödyntämiseen liittyviä jännitteitä

Tekoälyn vallankumouksellisesta diskurssista huolimatta, ennakoivan analytiikan, algoritmien ja massadatan hyödyntämisen juuret ovat paljon kauempana kuin

digitalisoituneessa tai tekoälyn valloittamassa maailmassa. Matterland (2003, s. 10-11, 16–18) kuvaa ennakkoinnin alkuperäiset juuret pitkälle matematiikan kehitykseen. Todennäköisyyslaskennan perusta luotiin 1660-luvulla, ja jo tuolloin siitä tuli uusi tapa tarkastella inhimillisiä yhteiskuntia. Ensimmäiset laajat kuolleisuustilastot julkaistiin vuonna 1693. Yksi kuolleisuustilastojen keräämisen päämäärinä oli tarjota välineitä henkivakuutusten myyntiä varten. Myös tilastotiede tarjosi jo varhain tavan tehdä valintoja epävarmassa maailmassa. Väestönlaskenta sai vuonna 1725 tieteellisen legitimitetin. Haittakysymykset nousivat esiin jo alkumetreillä: esimerkiksi Englanti vastusti yleistä väestönlaskentaa yksilön oikeuksien kunnioittamisen nimissä. Yksi ensimmäisistä algoritmeista syntyi irlantilaisen George Boolean kehittämänä vuonna 1854. Tämä muovasi tulevaisuuden polun lukujärjestelmien sekä laskentatapojen automatisoinnin ja digitalisoinnin kehittymiselle.

Matterland (2003, s. 80-86) kuvaa, kuinka tieteellisen liikkeenjohdon lanseeraama oletus siitä, että yhteiskuntaa voidaan hallita tehokkuuden ja rationaalisuuden periaattein, on heijastunut pitkälle informaatioteknologiaan ja sen muovaaman yhteiskunnan kehitykseen. Toisaalta Stenvallin ja Virtasen (2021, s. 131) mukaan digitaalisuuden ei tarvitse olla vastakkain nykyajan hallintoa ohjaavan pehmeämmän arvon, ihmiskeskeisyyden, kanssa. Monelle teknologia voi tarkoittaa vähemmän inhimillisyyttä, mutta digitalisaatio voi tarjota myös ratkaisuja ihmisille merkityksellisiin ongelmiin. Tämä tekee digitalisaatiosta hyvinkin ihmiskeskeistä, vaikka esimerkiksi eettisiä haasteita ei voida väheksyä.

Autoniemen (2021, s. 144; ks. myös Autoniemi 2020) kuvaamana tekoäly soveltuu kapeaan kontekstiin, jossa päätöksenteon säännöt ovat yleisiä, tarkasti määriteltyjä, muuttumattomia ja siten helposti opittavia. Byrokraattinen hallintomalli, jossa ratkaistavat asiat ovat kahtiajakoisia ilman eettisiä tai ideologisia piirteitä, soveltuu tekoälylle parhaiten. Kuitenkin juuri sosiaali- ja terveyspalveluissa arvolatautuneet kysymykset ovat päivittäin läsnä. Algoritmien hyödyntämisen yhteydessä ei ole tarpeeksi ei ole käsitelty esimerkiksi yksityisyyden kysymyksiä (Strang & Sung, 2020, s. 996). Lisäksi

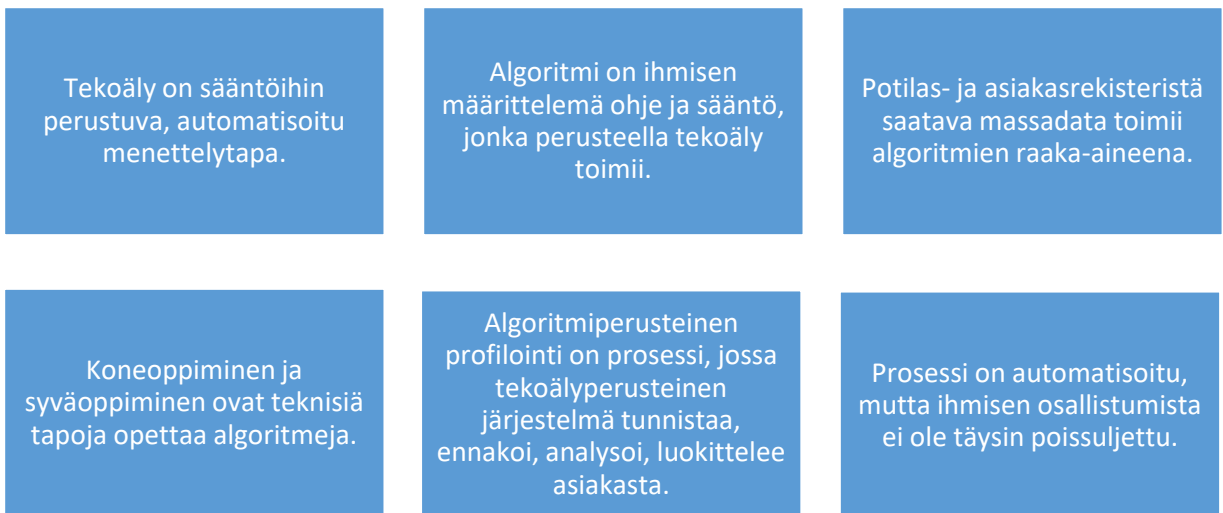
tekoälypohjaisten ratkaisujen ongelmana on, että ne koskevat jo hoidon piirissä olevia: ongelmana on tavoittaa henkilöt, jotka ovat tieto- ja palvelujärjestelmien ulkopuolella (Kivipelto & Suhonen, 2020, s. 2). Terveydenhuollon digitalisaatiossa huomio olisikin kiinnitettävä koko palveluprosessiin yksittäisten teknologisten ratkaistujen sijaan (Jones ja muut, 2012, s. 2243–2245).

Parviainen ja Rantala (2020, s. 7–8; ks. myös Matterland, 2003) kirjoittavat myös teknologiasta hallinnan ja sääntelyn muotona. Keskeistä olisi, ettei olemassa olevaa sääntelyä ohitettaisi, vaikka houkutus teknologisten innovaatioiden käyttöönottoon olisi suuri. He muistuttavat, että teknologisten sovellusten käyttöönotto on vain harvoin poliittisesti neutraalia ja tuovat esiin tekoälysovellusten kehittäjien kaupalliset intressit. Yksilön voi olla vaikea sisäistää, että hänen tuottamansa massadata saattaa hyödyttää enemmän kaupallisia toimijoita kuin hänen toivomiaan julkisia palveluja. Parviaisen ja Rantalan (2020) mukaan poissuljettua ei myöskään ole esimerkiksi terveydenhuollon sovellusten ja alustojen myyminen eteenpäin ulkomaisille yhtiöille, kuten on tehty aikaisemmin muun valtiollisen omaisuuden kanssa. Näitä kaikkia tulisi arvioida, kun tekoälyä sovelletaan.

2.5 Yhteenveto käytettävistä tekoälyn käsitteistä

Tässä tutkielmassa tekoäly viittaa sääntöpohjaiseen, automatisoituun malliin (ks. myös LeCun ja muut, 2015, s. 436; Autioniemi, 2021, s. 140). Tekoälyn jäsentäminen sääntöpohjaisena automatisoituna mallina mukaillee myös algoritmin perusolemusta ohjeena tai kuvauksena. Lisäksi suomalaisessa hallintotoiminnassa tekoäly tunnetaan sääntöpohjaisena mallina, jossa tietojärjestelmä tekee itsenäisesti lopullisen hallintopäätöksen, ihmisen määrittelemien päätöksentekosääntöjen perusteella. Täysin itsenäisen tekoälyn hyödyntäminen suomalaisessa julkishallinnossa on vielä vähäistä (Oikeusministeriö 2020 s. 11, s. 15–16).

Tässä tutkielmassa monialaisen palveluntarpeen tekoälyperusteinen tunnistaminen ymmärretään algoritmiperusteisena profilointina EU:n yleisen tietosuojasetuksen (2016/679) mukaisesti. Algoritmiperusteisen profiloinnin käsite tukee myös asiakasprofiloinnin käsitettä, johon viitataan monialaisen palveluntarpeen tunnistamisen yhteydessä luvussa 3. Profiloinnilla tarkoitetaan siten henkilön ominaisuuksien, piirteiden, käyttäytymisen, sairauksien ja riskitekijöiden tunnistamista, ennakoimista sekä analysointia potilas- ja asiakastiedoista saatavien tietojen perusteella sosiaali- ja terveystietopalveluissa. Tavoitteena voi olla palveluntarpeen tunnistaminen tai ennusteiden tai riskiarvioiden laatiminen sekä palvelujen suuntaaminen. Kuvio 1 havainnollistaa teknologisten käsitteiden jäsentymistä.



Kuvio 1. Tutkielman teknologisten käsitteiden jäsentyminen.

3 Monialainen palveluntarve sosiaali- ja terveystaloudessa

Suurin osa julkisen sosiaali- ja terveydenhuollon kustannuksista on syntynyt pienen väestön kerryttämänä (Berk & Monheit, 2001, s. ; Garfinkel ja muut, 1988, s. 41; Kapiainen ja muut 2010, s. 4; Leskelä ja muut, 2013, s. 3163; Valtiontalouden tarkastusvirasto 2017). Tälle väestöryhmälle ei ole yhtä selittävää määritelmää. Rosengardin ja muiden mukaan (2007, s. 6-7) tutkimuskirjallisuudessa kuvaus linkittyy usein käsitteisiin ”kompleksiset” tai ”moninaiset” tarpeet (*complex and multiple needs*). Näitä termejä käytetään vaihtelevasti ja erilaisin yhdistelmin, esimerkiksi *complex health needs*. Vastaavia kansanvälisessä tutkimuskirjallisuudessa käytettyjä termejä ovat *high need* ja *high cost patients* (Hujala & Lammintakanen, 2018, s. 16–17). Tällä viitataan paljon tai kalliita palveluja käyttäviin asiakkaisiin (Haula & Peltola, 2020, s. 30; Hietapakka ja muut, 2020, s. 41).

Hujalan ja Lammintakanen mukaan (2018, s. 16–18) kaikki vieraskieliset termit eivät valitettavasti suomalaisessa kontekstissa käänny asianmukaisesti. Epäonnistuneempia kuvauksia on ollut viittaaminen vaikeisiin ja hankaliin potilaisiin tai palvelujen monikäyttäjiin ja suurkuluttajiin (englanniksi *high users* ja *heavy users*). Myös kompleksiseen tai moninaiseen palveluntarpeeseen viittaavat käsitteet saattavat olla leimaavia asiakkaan näkökulmasta (Rosengard ja muut, 2017, s. 105). Lisäksi ristiriitaa on käsitteiden tulkinnassa: monien palvelujen käyttö ei välttämättä ole kallista palvelujen käyttöä, sillä palvelujen luokitteluun ja ryhmittelyyn on erilaisia tapoja. Ei ole yksiselitteistä määritelmää sille, monenko eri alan palveluja henkilön tulee käyttää, jotta kyseessä katsottaisiin olevan monialainen palveluntarve. (Koivisto ja Tiirinki, 2020, s. 12, s. 86)

Konsensusta ei myöskään ole siitä, mitä moninainen tai kompleksinen palveluntarve pitää sisällään. Vallitseva oletus näyttää olevan, että kompleksinen ja moninainen palveluntarve ovat itsestään selviä, keskenään verrannollisia ja tulevat ymmärretyksi ilman määritelmää. Tarkempi käsitteellinen määrittely olisi kuitenkin tärkeää, jotta

tarvittavia palvelustrategioita, resursseja ja politiikkatoimia voidaan allokoida asianmukaisesti (Rosengard ja muut, s. 6-7, s. 14).

3.1 Käsitteellisiä lähestymistapoja palveluntarpeen määrittelyyn

3.1.1 Paljonko ja mitä palveluita?

Tavallisesti paljon sosiaali- ja terveyspalveluita palveluita käyttävät henkilöt (*frequent attenders, persistent frequent attenders*) määritellään sen perusteella, montako käyntiä potilaalla on ollut viimeisen 1-2 vuoden aikana perusterveydenhuollossa. Raja-arvona on perinteisesti pidetty 24 kontaktia vuoden aikana. (Hauswaldt ja muut, 2013, s. 1–3; Yli-Katajisto, 2019, s. 22) Suomalaisen työterveyshuollon kontekstissa paljon palveluita käyttävien vuosittaiseksi keskiarvoksi on saatu 13 käyntiä vuodessa (Reho ja muut, 2018, s. 1). Yli-Katajisto (2019, s. 25, s. 86) määritteli paljon palveluita tarvitseväksi henkilön, jolla on yli kuusi käyntiä vuodessa perusterveydenhuollon lääkärin vastaanotolla, tai jolla on ammattilaisen tunnistamana tarve monialaiselle osaamiselle. Toisaalta Yli-Katajiston (2019) mukaan, pelkästään perusterveydenhuollon käyntimäärä ei ole riittävä mittari paljon palveluja tarvitsevan asiakkaan tunnistamisessa.

Myös Hauswaldtin ja muut (s. 3-7) esittivät, ettei käyntimäärien tarkastelu vuositasolla anna riittävän täsmällistä tietoa palvelujen käytöstä. Heidän mukaansa yksi vaihtoehto olisi määritellä paljon palveluita käyttävät hoitokontaktien välissä kuluvan ajan perusteella (*inter-contact time measure*). Hauswaldt työryhmineen analysoi potilasdataa asiakkaista, joilla oli useampi kuin kaksi käyntiä perusterveydenhuollossa Saksassa vuosina 1996-2006. Heidän mukaansa potilaan ja lääkärin tapaamisen välinen mediaani oli 37,3 ja keskiarvo 64,1 päivää. Aineiston useimmiten esiintyvä arvo (moodi) oli 14 päivää. Myös 7 päivän välein toistuva tapaaminen oli suhteellisen yleinen, samoin 90 päivää, minkä tosin tulkittiin selittyvän resepteihin uusimiseen liittyvillä käynneillä. Tarkemmin tarkasteltuna noin 11,2% hoitokontakteista toistui 1-6 päivän aikajänteellä. Tämän Hauswaldt (2013) työryhmineen tulkitsi edustavan lyhytaikaista väliä tapaamisten

välillä, mikä voisi indikoida toistuvaa palveluntarvetta. Arvioon liittyy kuitenkin epävarmuustekijöitä, kuten kulttuuri- ja palvelujärjestelmäkohtaisia eroja. Palvelujen käytön määrällistä mittaamista hankaloittaa myös tietojen puute. Sosiaalihuollon rekisteritiedot ovat monelta osin puutteellisia, jonka vuoksi tietoa paljon palveluja tarvitsevien asiakkaiden käynneistä esimerkiksi sosiaalityön vastaanotolla ei ole, eikä tästä ole myöskään voitu tuottaa tutkimustietoa (Yli-Katajisto, 2019, s. 22).

Määrällinen tieto ei myöskään anna tietoja palvelujen käytön syystä. Kivelän, Elon ja Kääriäisen (2018, s. 115–116) mukaan henkilöt, jotka hakeutuvat sosiaali- ja terveyspalvelujen piiriin usein, tuntevat oireiden lisäksi terveydentilansa ja elämänlaatunsa heikentyneen. Hauwaldt työryhmineen (2013, s. 4–5) havaitsivat että henkilöt, joiden hoitokontaktien välinen aika oli 1-6 päivää, tulossyynä vastaanotolle oli usein keuhkokuume, aivohalvaus, muistisairaus. Astma, nivel tulehdus tai verenpainetauti olivat vain harvoin tulossyynä, mikä Hauwaldtin ja muiden mukaan poikkeaa aikaisemmista paljon palveluita käyttäjien henkilöiden tutkimuksista. Mielenterveyspotilaiden palveluntarve ei Hauwaldtin ja muiden tutkimuksessa näyttäytynyt yhtään haastavammalta muihin potilasryhmiin verrattuna, vaikka usein juuri mielenterveyspotilaat saatetaan mieltää runsaasti palveluita tarvitseviksi. Vastaavasti aivohalvaus, dementia ja sydänkohtaus olivat syitä kohonneelle palveluntarpeelle, mikä toistui niin Hauwaldtin ja työryhmän tutkimuksessa kuin myös heidän kartoittamissaan aikaisemmissa tutkimuksissa. Suomessa tuki- ja liikuntaelinvaivat ovat yksi yleisimmistä syistä hakeutua toistuvasti työterveyshuollon vastaanotolle (Reho ja muut, 2018, s. 8).

Yli-Katajisto (2019, s. 22, s. 86, 100) käyttää paljon palveluja *tarvitsevan* asiakkaan käsitettä, jotta mielikuva ei syntyisi pelkän käytön perusteella. Paljon palveluja tarvitsevien asiakkaiden kohdalla huomion tulisi painottua määrälähtöisyyden sijaan sote-palvelujen tarpeeseen, jolloin huomioidaan yksilöllisten erojen lisäksi ammattilaisen tunnistama monialainen sosiaali- ja terveyspalvelujen tarve. Rankin ja Regan (2004) ottavat tarkasteluun vielä tarpeiden välisen yhteen kietoutumisen.

3.1.2 Kompleksisuus huomioi tarpeiden yhteen kietoutumisen

Rosengard ja muut (2007) nostavat kirjallisuuskatsauksessaan esiin Rankin ja Reganin tutkimuksen. Rankin ja Regan (2004, s. 4–8) kyseenalaistivat vallitsevaa tilaa, jossa palveluntarve määritellään väljästi monialaisena, kompleksisena. Laveasti katsottuna, käytännössä kaikki ihmiset omaavat kompleksisia ja moninaisia palveluntarpeita. Kenenkään tarpeet eivät rajoitu vain yhteen, vaan jokainen tarvitsee esimerkiksi toimeentuloa, pysyvän asuinsijan, merkityksellistä sisältöä elämään sekä sosiaalisia vuorovaikutussuhteita. Siten ei ole olemassa geneeristä kompleksista tai monialaista palvelun tarvetta. Jokainen henkilö on yksilö, joka vaatii yksilöllisesti kohdennettua palvelua ja vuorovaikutusta terveydenhuollon sekä sosiaalihuollon toimijoiden kanssa (Rankin & Regan, 2004, s. 4–8). Keskimääräistä enemmän tukea ja palveluita tarvitseva henkilö voi olla vanhus, työssä käyvä tai työtön aikuinen, lapsiperhe, nuori tai oikeastaan elämänvaiheen mukaan kuka tahansa (Hujala & Lammintakanen, 2018, s. 17).

Rankin ja Regan (2004) korostivat, että monialaisessa palveluntarpeessa kyse on erilaisten terveydellisten ja sosiaalisten kysymysten yhteenliittymästä. Henkilöt, joilla on moninaisia ja kompleksisia palveluntarpeita, omaavat erilaisia haasteita ja tilanteita. He voivat olla vailla asianmukaisia olosuhteita ja tukiverkostoja. Usein palveluntarpeen tunnistaminen epäonnistuu juuri siksi, ettei eri ominaisuuksien yhteisvaikutuksia osata arvioida riittävästi. Henkilön tarpeita tulisikin katsoa kokonaisuutena ja huomioida myös erilaisten tarpeiden välinen vuorovaikutus. Palveluntarpeen tunnistaminen kontekstissa tämä tarkoittaa Rankinin ja Reganin (2004, s. 4–8) mukaan, että useiden diagnoosien asettamisen sijaan katsotaan myös henkilön sosiaalisia olosuhteita. Palveluntarpeella on siten eri ulottuvuuksia, syvyyksiä ja leveyksiä: syvyys viittaa tarpeen kovuuteen, leveys kuvaa tarvittavien palvelujen valikoimaan.

Erilaisten tarpeiden yhteen kietoutuneisuuden tunnistaminen ja katsominen kokonaisuutena osaoptimoinnin sijaan kuvastaa olemukseltaan *kompleksisuusajattelua*.

Kompleksisuusajattelu ei ole varsinainen teoria tai malli, mutta se pitää sisällään ymmärryksen asioiden välisistä riippuvuuksista ja toisaalta myös asioiden itseohjautuvuudesta sekä ennakoimattomuudesta (Puustinen & Jalonen, 2020, s. 17–19). Kompleksisuusajattelun syntyyn on vaikuttanut systeeminen maailmankuva, jossa tarkastellaan kokonaisuutta ja keskinäisiä vuorovaikutussuhteita yksittäisten osien tarkastelun sijaan (Jalonen, 2010, s. 117–118). Kyse on siitä, että toiminnassa ymmärretään kytkeytyneisyys eli eri toimijoiden väliset yhteydet ja keskinäisriippuvuudet (Puustinen & Jalonen, 2020, s. 25).

3.1.3 Yhteisasiakkuus palveluntarpeen määrittelyssä

Hujalan ja Lammintakasen (2018, s. 16; ks. myös Oksman 2017, s. 2) mukaan yksi tapa määrittellä paljon tai monialaisia palveluja tarvitsevia asiakkaita on puhua yhteisasiakkaista. Yhteisasiakas tarvitsee palveluja monelta eri taholta. Viitaten edellä kuvattuun Rankin ja Reganin (2004) kuvaamaan, voidaan yhteisasiakkuuden käsite tulkita kuvaavaksi henkilön tarvitsemien palvelujen variaation sekä tarpeiden välisen vuorovaikutuksen näkökulmasta. Yhteisasiakkuus ei ole synonyymi asiakkaan vaikeuksille tai ongelmille, mutta kuvaa useamman ammattilaisen osaamisen tarvetta (Mönkkönen, 2007, s. 128).

Paljon palveluita tarvitsevien yhteisasiakkaiden asiakkaiden tukeminen edellyttääkin usein moniammatillista yhteistyötä (Hujala & Lammintakanen, 2018, s. 60; ks. myös Yli-Katajisto, 2019, s. 61). Isoherrasen (2012, s. 20-21) mukaan, suomalaisessa terveydenhuollossa *moniammatillisuus* tarkoittaa vaihtelevasti erilaisia määritelmiä ja sitä sovelletaan monenlaisissa viitekehyksissä. Sillä voidaan kuvata poikkitieteellistä ja ammattiryhmien välistä yhteistyötä. Hujalan ja Lammintakasen (2018, s. 60) mukaan, yhteisasiakkuuden käsite tai yhteisasiakkaiden palvelut eivät nojaudu kuitenkaan ainoastaan moniammatillisuuteen, vaan moniammatillisen tiimityöskentelyn rinnalle

tarvitaan myös uusia nopeita ja joustavia yhteistyön muotoja. Digitalisaation nähdään tuovan uusia mahdollisuuksia yhteisasiakkaiden hoitoon.

3.1.4 Tämän tutkielman käsitteelliset valinnat

Edellä on kuvattu joitain lähestymistapoja palveluntarpeen käsitteelliseen määrittelyyn. Tyhjentävää määritelmää ei tämän tutkielman puitteissa ole tarkoitus antaa. Tässä tutkielmassa käytetään käsitettä *monialainen palveluntarve*, joka kuvastaa tarpeiden moninaisuutta ja moniammatillisuutta, eikä rajaa tarkastelua palvelujen määrään tai tiheyteen. Potilaan sijaan tässä tutkielmassa käytetään *asiakkaan* ja *henkilön* käsitettä. Tasavertaista ja asiakaslähtöistä yhteistyötä on korvata sana potilas asiakkaan käsitteellä (Ristolainen ja muut, 2020, s. 243-248).

Aikaisemmissa tutkimuksissa on todettu, että monialainen palveluntarve tulee usein ilmi vasta asiakkaan tunnistamisen jälkeen (Kivipelto ja muut, 2019, s. 24). Koska tutkielman aihepiirinä on palveluntarpeen tunnistaminen, viitataan tässä tutkielmassa henkilöön, jolla on tai saattaa olla moninainen ja laaja palvelujen tarve nyt tai tulevaisuudessa. Kyse on sellaisten henkilöiden tunnistamisesta, jotka *tarvitsevat* tai joiden *ennakoivaan tarvitsevan* monialaisia ja moniammatillisia palveluita, siis useamman sosiaali- ja terveydenalan ammattilaisen osaamista. Palvelujen tarve voi olla pitkäaikainen, toistuva ja/tai yhteiskunnallisesti kallis. Monialaisen palveluntarpeen omaavalla asiakkaalla voi olla yksi tai useampi diagnosoitu sairaus, mutta diagnoosi voi myös puuttua kokonaan. Kuvio 1 kiteyttää tutkielmassa käytettävän monialaisen palveluntarpeen määritelmän.



Kuvio 2. Monialaisen palveluntarpeen määrittely tässä tutkielmassa.

3.2 Monialaisen palveluntarpeen tunnistamisen nykytila

Terveydenhuollon kustannusten alentamiseksi ja vaikuttavan, yksilöllisen terveydenhuollon tarjoamiseksi, monialaisen palveluntarpeen omaavat henkilöt olisi ensimmäiseksi tunnistettava (VTV 2017, s. 15; ks. myös Muurinen & Mäntyranta, s. 13). Sosiaali- ja terveystieteissä kustannusvaikuttavuus merkitsee, että käytössä olevien resurssien puitteissa kansalaisten terveyttä ja hyvinvointia edistetään mahdollisimman paljon (Sintonen ja Pekurinen, 2006, s. 57–59). Tunnistaminen on keskeisessä roolissa asiakkaan ohjaamiseksi hänen tarpeitaan vastaaviin palveluihin, ja palveluntarpeen

tunnistamiseen sekä tunnistamisen mallien kehittämiseen tulee kohdistaa entistä laajempaa huomiota (Koivisto & Tiirinki, 2020, s. 97–98).

Hujala ja Lammintakanen (2017, s. 21–28; Oksman 2017) kuvaavat, ettei nykyisessä sosiaali- ja palvelujärjestelmässä kenelläkään tunnu olevan vastuuta monialaisen palveluntarpeen omaavien asiakkaiden hoidon kokonaiskuvasta. Asiakkaat eivät hyödy palvelujen pirstaloituneisuudesta, ja ammattilaiset eivät tunne toistensa osaamista. Tämä vaikeuttaa yhteistyötä. Tietojärjestelmät eivät ole yhteensopivia, mikä aiheuttaa puutteita tiedossa. Potilastietojärjestelmiin integroitua Kanta-arkistoa ei ole koettu käyttökelpoiseksi käytännön työssä, sillä se ei arkistomaisen rakenteensa vuoksi edesauta potilastietojen koostamista ja siten asiakkaan kokonaistilan hahmottamista. Suomalaisen sosiaali- ja terveyspalvelujärjestelmän on sanottu olevan liian siiloutunut (Rautiainen ja muut, 2020, s. 35). Toisaalta EU-maaraporttien mukaan suomalainen sosiaali- ja terveyspalvelujärjestelmä on verrattain hyvin integroitu, ja palvelut ovat sijoittuneet paikallistasolle koko maan kattavasti (Sinkkonen ja muut, 2018, s. 106). Myös sote- ja hyvinvointialueuudistuksen yhtenä tarkoituksena on edistää palvelujen yhteen toimivuutta, jotta palveluketjut ovat tulevaisuudessa yhteensovitettuja sekä katkeamattomia kokonaisuuksia (Laki sosiaali- ja terveydenhuollon järjestämisestä, 612/2021, 1 §; Valtioneuvosto, 2022). Erityisesti monialaisen palveluntarpeen omaavien asiakkaiden on sanottu hyötyvän palvelujen yhtenäistämistä (Hujala ja Lammintakanen, 2017, s. 62; Rautiainen ja muut, 2020, s. 35).

Yhtenäisten palvelujen edistämiseksi on kehitetty myös lukuisia muita malleja, esimerkiksi palveluohjausta ja asiakkaalle nimettyyn omatyöntekijään perustuvia toimintatapoja (Kivipelto ja muut, 2019, s. 5). On osoitettu, että asiakkaiden aktiivinen osallistuminen hoitoon edistää terveyttä ja voi alentaa terveydenhuollon kustannuksia (James, 2013). Lähes kaikkien sosiaali- ja terveydenalan toimintojen lähtökohtana on nykyään asiakaslähtöisyys (Ristolainen ja muut, 2020, s. 243). Asiakaslähtöisyyttä määritellään monin tavoin, mutta yhdellä tapaa tarkasteltuna se tarkoittaa siirtymistä järjestelmälähtöisistä palveluista ihmiskeskeisempään ajatteluun. Ihmiskeskeisessä

ajattelussa palveluja tarkastellaan palvelun käyttäjän, ei palvelun tuottavan organisaation näkökulmasta. (Van der Heide ja muut, 2017, s. 36–37) Asiakkaan ja hänen omaistensa tulee voida osallistua hoitoprosessien suunnitteluun tasavertaisina kumppaneina, ja asiakkaan omahoitoa tulee tukea (Ristolainen ja muut, 2020, s. 243-248). Asiakslähtöisyyttä pyritään edistämään lainsäädännöllä, esimerkiksi ohjaamalla henkilökohtaisen asiakas- tai palvelusuunnitelman laatimiseen (Sosiaalihuoltolaki 1301/2014, Laki sosiaalihuollon asiakkaan asemasta ja oikeuksista 812/2000, Terveydenhuoltolaki 1326/2010). Asiakas- ja palvelusuunnitelman käsitteitä käytetään vaihtelevasti ja osin synonyymeinä. Asiakassuunnitelma on kiinteä osana palveluprosessia, jossa sosiaali- ja terveydenhuollon ammattilainen arvioi asiakkaan palvelujen tarpeen. Asiakassuunnitelma toimii pohjana ja perustana palvelujen toteutumiselle, mutta ei ole oikeudellisesti sitova, kuten viranomaisen hallintopäätös. Asiakassuunnitelma kuitenkin tukee asiakkaan asemaa sekä hoito- ja palveluketjun jatkuvuutta. (Ristolainen ja muut, 2020, s. 243-248)

Lainsäädännöstä huolimatta käytänteet monialaisen palveluntarpeen omaavien asiakkaiden asiakassuunnitelmissa ovat kuitenkin kirjavat. Esimerkiksi Parempi arki -hankkeessa havaittiin, että asiakkaalla saattoi olla kymmeniä erilaisia palvelusuunnitelmia ja kymmeniä asiakkaan asioita hoitavia lääkäreitä (Ristolainen ja muut, 2020, s. 253; Oksman 2017 mukaan). Myöskään valtaosassa Suomen sosiaali- ja terveydenhuollon organisaatioita ei ole sovitusti käytössä mitään nimenomaisesti monialaisen palveluntarpeen tunnistamiseen soveltuvaa työkalua (Koivisto ja Tiirinki, 2020, s. 97–98; VTV, 2017, s. 15). Valtiontalouden tarkastusviraston suorittaman selvityksen (2017, s. 15–16) mukaan, kaikkien terveyskeskusten alueilla ei ollut suunnitelmaa monia palveluja tarvitsevien asiakkaiden tunnistamiseen. Näillä alueilla asui väestöä yhteensä yli 2,5 miljoonaa henkilöä. Useissa terveydenhuollon toimipaikoissa monialaisen palveluntarpeen tunnistamiseen ei edes aktiivisesti pyritty, vaan seulonta rajoittui tiettyihin ryhmiin, kuten iäkkäisiin. Tällöin muut monisairaajat tai paljon palveluita tarvitsevat asiakkaat jäivät tunnistamatta. Niissä terveyskeskuksissa, joissa tunnistamiseen kuitenkin kiinnitettiin huomiota, menettelytavat eivät olleet

säännönmukaisia. Yleisin tunnistamisen tapa oli terveydenhuollon ammattilaisen asiantuntemuksen perusteella laatima arvio, joka muodostui hyvin vaihtelevin periaattein ja rajoittui pääsääntöisesti vain palvelujen käytön määrän tarkasteluun.

Kivipelto ja muut (2019, s. 22–24) kartoittavat monialaisen palveluntarpeen tunnistamisen malleja niin kansallisesti kuin kansainvälisesti. Yhteenvetona oli, että mallien painotus oli runsaassa tai jatkuvassa sote-palvelujen käytössä sekä näiden tarkastelussa. Palvelujen suurkäytön lisäksi tunnistamisen välineitä voidaan luokitella myös riskiryhmien ennakointiin, ensiapu- ja päivystyskäyntien ennakointiin, sairaalakäyntien ennakointiin sekä kalliiden potilaiden tai asiakkaiden tunnistamiseen. Monialaisia palveluja tarvitsevien henkilöiden tunnistamiseen ja ennakointiin käytettiin mm. kyselypohjaisia mittareita, käyntimääriä ja taloustieteellisiä malleja. Kivipellon ja muiden (2019) toteuttaman kirjallisuuskatsauksen päätelmät olivat linjassa aikaisempien näkemysten kanssa siitä, että sosiaali- ja terveydenhuollossa on tarve palvelujen käytön ennakoinnille. Erityisesti tarvitaan tukea monialaisen palveluntarpeen omaavien ja integroiduista palveluista hyötyvien henkilöiden tunnistamiseen. Tunnistamisen kautta saatujen tietojen nojalla saatettiin esimerkiksi linjata resursseja ja käsitellä tunnistamisesta saatua tietoa moniammatillisesti. Taulukkoon 1 on listattu eräitä tunnistamisen työkaluja Kivipellon ja muiden (2019) aineistoa mukaillen.

Taulukko 1. Palveluntarpeen tunnistamisen mallit Kivipelto ym. (2019) mukaillen.

Mallin nimi, alkuperämaa, lähde & käyttötarkoitus	Tulokset
<p>Potilastietoista tehtävä poiminta. <i>Comprehensive Care Centers and Homecare Program</i>. USA (Feder, 2011). Mallissa tunnistetaan sairaalasta vastikään kotiutuneet ja vakavia keuhko- tai sydänsairauksia sairastavat henkilöt. Potilasrekisteristä haetaan kotiutettujen henkilöiden tiedot, jonka jälkeen arvioidaan riski vakavalla keuhko- tai sydänsairaudelle. Tunnistetuille henkilöille järjestetään lääkärin tai sosiaalityöntekijän tapaaminen. Asiakkaan tilannetta (terveydentila, lääkitys, talous, asuminen, liikkuminen) voidaan seurata myös puhelimitse.</p>	<p>Kaksivuotisen intervention aikana henkilöiden sairaalassa olo väheni 20 %. Edellyttää aikataulujen joustavuutta: mikäli asiakkaan terveydentilassa tai palveluntarpeessa ilmenee muutostarpeita, ajan terveysasemalle tulisi järjestyä nopeasti.</p>

<p>Mielenterveyspainotteiset mittarit ja kyselyt: sairauksiin liittyvä asennemittari <i>The Illness Attitude Scales (IAS)</i>. Hollanti (Smits ym, 2014). Mittaa terveyshuoliin liittyviä pelkoja, asenteita ja uskomuksia. Elämäntapahtumamittari <i>Life Event Questionnaire (LEQ)</i> mittaa asiakkaan negatiivisia elämäntapahtumia kuluneen 3-12 kk aikana, joilla voi olla vaikutusta lisääntyvään palveluntarpeeseen. Hollannissa tehdyssä kohorttitutkimuksessa hyödynnettiin edellä mainittuja kyselyyn perustuvia mittareita.</p>	<p>Ahdistus- ja paniikkioireet, ja vaikeat elämäntapahtumat menneen vuoden aikana yhdistettynä henkilön terveyskäyttäytymiseen ja heikkoon elämänhallinnan tunteeseen voivat liittyä perusterveydenhuollon käyttöön seuraavan kahden vuoden aikana.</p>
<p>Kalliiden potilaiden ennakoitumallit. Terveystaloustieteellinen arviointimalli <i>Disease Management Program (DMP)</i>. Saksa (Gandjour, 2010). Malli pyrkii pitkän aikavälin kustannusseurantaan ja arviointiin. Malli havainnoi sairauden esiintyvyyttä populaatiossa, lääkärillä käyntien määrää ja aikaa sekä toteutunutta hoitoa. Mallin avulla voidaan laskea alhaisen ja korkean riskin omaavien potilaiden kustannuksia. Gandjour (2010) sovelsi mallia verenpainetautiin liittyvän hoidon kokonaiskustannuksien arviointiin.</p>	<p>Mallin avulla onnistuttiin laskemaan rajakustannuksia sekä määrittelemään alhaisen ja korkean riskin omaavan potilaan ominaisuuksia verenpainetautiin liittyvässä hoidossa.</p>
<p>Telemonitorointiin perustuva biometristen riskitekijöiden arviointi. Valcronic-ohjelma, Espanja, Valencian alue (Espanja, Valencian alue (Doñate-Martínez ym, 2016). Kohderyhmänä ikääntyneet. Valcronic-ohjelman avulla voidaan arvioida tietoa biologisista, kuten verenpaineen ja verensokerin, muutoksista, ja ennakoida ikääntyneen pitkäaikaissairaana kohonnuttua riskiä joutua sairaalahoitoon. Potilaat lähettävät ohjelmassa tarvittavat tiedot itse terveysasemille esim. älypuhelimien kautta. Henkilökunta voi saadun tiedon perusteella arvioida ja kontrolloida asiakkaan tilannetta.</p>	<p>Laitteiden käyttö koettiin helpoksi, käytössä teknisen tuen puhelinkeskus. Terveyspalvelujen käyttö väheni ohjelman myötä 51%:lla. 40 % koki yhteydenpidon ammattilaisten kanssa helpottuneen. Kaikki osallistuneet kokivat elämänlaatunsa parantuneen. Yli 50 % muutti elintapojaan terveellisemmiksi telemonitorointiseurannan aikana.</p>

3.2.1 Aikaisempi kirjallisuus profiloinnista ja digitalisaatiosta osana monialaisen palveluntarpeen tunnistamista

Tuulaniemen (2011, s. 155-156) mukaan *asiakasprofiili* on tietyn ryhmän kuvaus. Asiakasprofiileja on jo vuosia hyödynnetty markkinoinnissa ja palvelumuotoilussa.

Asiakasprofiilin avulla kiteytetään henkilön käyttäytymistä ja tarpeita. Huolellisesti rakennetut asiakasprofiilit toimivat suunnittelutyökaluna sekä ideointiin, päätöksentekoon että palvelujen rakentamiseen. Profilointi auttaa myös palvelujen kohdentamisessa ja viestimisessä, mikä tekee palveluista helpommin saavutettavia.

Profilointi ei ole uusi ilmiö, myöskään sosiaali- ja terveystaloudissa. Yli-Katajisto (2019, s. 85–88) esitti, että profilointi sellaisenaan voi olla osa monialaisen palveluntarpeen tunnistamista, myös ilman tekoälyn tai automatisoinnin kontekstia. Yli-Katajisto (2019) kuvasi väitöstutkimuksessaan paljon palveluita tarvitsevia asiakasprofiloinnin kautta. Väitöstutkimus vahvisti näkemystä siitä, että paljon palveluja tarvitsevien asiakkaiden asiakasprofiilissa erottuvat niin psykofyysiset kuin myös sosiaaliset ongelmat ja näiden väliset kytkökset. Asiakasprofiileista oli tunnistettavissa fyysisiä oireita tai sairauksia, kroonisia sairauksia, psyykkisiä tai psykosomaattisia oireita tai sekä sosiaalisia ongelmia. Asiakkailta oli siten tarve monialaisiin sote-palveluihin. Määritetyt asiakasprofiilit tukivat myös aikaisempia näkemyksiä asiakkaiden kirjavista palvelutarpeista sekä vaihtelevista tavoista hakeutua palveluihin. Erot asiakasprofiilien välillä olivat esimerkiksi tavoissa asioida terveyskeskuksessa (esim. paikan päällä, puhelimitse tai sähköisesti).

Samankaltaisuutta moninaisuutta ilmeni myös Etelä-Savon sosiaali- ja terveystaloudien kuntayhtymän ESSO-hankkeessa (2016), jonka yhtenä osa-alueena oli paljon terveystaloudia käyttävien asiakkaiden profilointi. Tarkoituksena oli syventää asiakasymmärrystä asiakasprofiloinnin avulla. Aineisto kerättiin haastattelujen ja niiden analyysin keinoin. Kenelläkään haastateltavista ei ollut vain yhtä, selkeää diagnoosia. Hankkeen lopputuloksena syntyi viisi erilaista asiakasprofiilia: hätäantunut oireilija, vaivan häpeilijä, varovainen kroonikko, terveysharrastaja ja tiedostava sairausmanageri. Yleisiä havaintoja koskien kaikkia asiakasryhmiä oli, että kukaan ei nukkunut kunnolla ja he kokivat jääneensä oman onnensa nojaan. Toisaalta terveystaloudet toimivat myös tietynlaisena turvaverkkona. Lisäksi hoidon organisointi itselle tai omaiselle oli vaikeaa. ESSO-hankkeen (2016) lopputuloksena havaittiin, että asiakasprofiili muuttuu ajan kuluessa. Karkeasti potilaat voitiin tulosten perusteella jakaa myös kahteen ryhmään.

Ensimmäisen ryhmän potilaat tarvitsivat lähtökohtaisesti kuuntelua, ja heidät tulkittiin voivan palvella myös etäyhteyksin. Lisäksi jaottelu tehtiin potilaisiin, joiden palveluntarve katsottiin kompleksiseksi, ja jotka siten tarvitsivat perusterveydenhoidon ja erikoissairaanhoidon integroituja palveluja.

Sosiaali- ja terveydenhuollon palveluissa asiakasprofilointia on hyödynnetty kansainvälisesti esimerkiksi toistuvasti ensiapuun hakeutuvien asiakkaiden profiloinnissa. Moore ja muut (2009, s. 266–267; ks. myös Koivisto ja muut 2019, s. 18) havaitsivat vuoden kestäneessä seurantatutkimuksessaan, että useimmin päivityksessä käyneet olivat todennäköisemmin vanhempia miehiä. Samaan aikaan heidät luokiteltiin yhä useammin vaativan ensihoidon tarpeessa oleviksi henkilöiksi. Riski kohonneelle palvelujen tarpeelle näyttäisi kasvavan neljännen käyntikerran jälkeen. Johtopäätöksenä oli, että saatua tietoa voitaisiin hyödyntää paitsi päivystykseen liittyvien palvelujen kehittämisessä, myös palvelujen organisoinnissa päivitysvastaanottojen ulkopuolella.

Myöskään digitalisaatio tai algoritmit eivät ole täysin uusi asia monialaisen palveluntarpeen tunnistamisessa. Kivipelto ja muiden (2019, s. 24) toteuttamassa kirjallisuuskatsauksessa, myös algoritmeja sekä massadataa hyödynnettiin jo aikaisemmin monialaisen palveluntarpeen tunnistamisessa. Asiakas- ja potilastietokannoista seulottiin diagnoosien ja käyntimäärien lisäksi myös kotiutuksia sekä tulosityitä vastaanotolle. Myös asiakkaaseen vaikuttaneita kriisitapahtumia tarkasteltiin. Kuitenkin Suomessa Valtiontalouden tarkastusviraston (2017, s. 20–21) tekemän selvityksen mukaan, Suomessa noin 44 % sosiaali- ja terveyspalvelujen johtajista ei katsonut potilastietojärjestelmiä käyttökelpoisiksi asiakkaiden palveluntarpeen tunnistamisessa. Vastaavasti hieman alle puolet kokivat sähköiset potilastietokannat myös hyödyllisiksi monialaisen palveluntarpeen tunnistamisessa. Valmius potilastietojärjestelmien käyttämiseen monialaisen palveluntarpeen tunnistamisessa ei nykyisissä terveyskeskuksissa näyttäytynyt erityisen hyvänä, ja potilastietojärjestelmiä hyödynnettiin vain harvoin. Potilastietojärjestelmien käytön

esteenä palveluntarpeen tunnistamisessa koettiin mm. tietojärjestelmien yhteen toimimattomuus sekä tietosuojaan ja vaitiolovelvollisuuteen liittyvät näkökulmat.

3.2.2 Nykytilan haasteet – yhteenveto monialaisen palveluntarpeen tunnistamisesta

Edellä on kuvattu monialaisen palveluntarpeen tunnistamisen nykytilaa. Lainsäädännöstä ja hyvistä aikomuksista huolimatta, monialaisen palveluntarpeen tunnistaminen sekä myös hoitoon pääseminen näyttäytyvät kuitenkin puutteellisina. Valtiontalouden tarkastusviraston (VTV, 2017, s. 15–18) selvityksessä havaittiin, ettei kaikilla monisairailta tai ilman diagnoosia olevilla ollut mahdollisuutta päästä palvelujärjestelmän piiriin, vaikka tarve palveluille olisikin näyttäytynyt selvänä ja runsaana. Toisaalta terveydenhuollon ammattilaiset kuvasivat VTV:n selvityksessä myös asiakkaita, jotka käyttävät runsaasti palveluja, mutta jotka eivät ammattilaisen arvion mukaan varsinaisesti hyödy niistä. Silti osa näistä asiakkaista hakeutuu toistuvasti esimerkiksi terveydenhuollon vastaanotolle.

Tässä kappaleessa on kuvattu erilaisia monialaisen palveluntarpeen tunnistamisen malleja. Kivipelton ja muiden (2019, s. 23–24) kuvaamana, keskeisenä haasteena mallien käytössä on tapauskohtaisiin ja yksilöllisiin tarpeisiin liittyvän punnitsemisen vähentyminen. Tämän vuoksi Kivipelto ja muut (2019) huomauttavat, että malleihin tulee yhdistää tapauskohtainen arviointi, ammatillinen harkinta sekä moniammatillinen keskustelu. Asiakslähtöisyyden näkökulmasta puutteena on, että tunnistamisen malleissa asiakkaiden osallisuutta ei tuoda kovin aktiivisesti esiin. Kivipelto ja muut (2019) huomauttavat, että mallien tarkoitus ei ole estää asiakkaan mahdollisuutta osallistua itseään koskevaan päätöksentekoon, vaan asiakkaan osallisuus pitää turvata kaikissa tilanteissa. Kansainvälisiä malleja, erityisesti amerikkalaisia, sovellettaessa huomio tulee kiinnittää myös mm. vakuutusjärjestelmästä lähteviin eroavaisuuksiin.

Vaikka Suomessa on aikaisemmin esitetyn mukaisesti hanketyön ja väitöskirjatutkimuksen myötä esimerkkejä asiakasprofiloinnista osana monialaisen

palveluntarpeen tunnistamisesta, liittyy tähän myös ristiriitoja. Jalosen (2010, s. 118) mukaan, kohderyhmäperusteisella palvelujen järjestämisellä ja tunnistamisella on hyvät, asiakaslähtöiset tavoitteet. Kuitenkin käytännön toteutus voi olla vaikeaa, sillä moninaiset tarpeet noudattavat vain harvoin sektorikohtaisia rajoja. Myös Vironkangas (2017, s.278–281) pitää ongelmallisena sitä, että palvelut määritellään tietynlaisissa elämäntilanteissa oleville ja kategorisoiduille asiakkaille sopiviksi. Lisäksi tietyn asiakasprofiilin edellyttäminen voi estää palveluihin pääsyn. Ihanteellisinta olisi mukauttaa palveluita asiakkaan tarpeiden mukaan. Järjestelmälähtöisesti määritellyt palvelut ja niiden sisällöt eivät myöskään välttämättä edesauta asiakasta itseään löytämään ja tunnistamaan hänelle sopivia palveluita. Mikäli palvelu edellyttää esimerkiksi sosiaalihoitolain mukaista hallintopäätöstä, voi päätöksen puuttuminen estää palveluihin pääsyn.

Vironkangas (2017) esittää, että rajaamisen ja käännättämisen sijaan, palvelujen tulisi perustua mukaan ottamiseen ja kokonaisvaltaisuuteen. Tilanteessa, jossa palvelut eivät mukaudu asiakkaan tarpeisiin, ratkaisun tulisi olla palvelujen muutos, ei asiakkaan rajaus. Huomionarvoista on myös, että Kivipellon ja muiden (2019, s. 9) toteuttamassa kirjallisuuskatsauksessa, jossa kartoitettiin monialaisia palveluja tarvitsevien tunnistamisen ja ennakoinnin malleja, aineistossa oli mukana vain yksi julkaisu, jossa potilastietojen perusteella pyrittiin tunnistamaan sosiaalisen tuen tarpeessa olevia. Tämän perusteella tulkittuna palveluntarpeen tunnistaminen näyttää painottuvan selkeämmin terveydenhuoltoon ja somaattisiin oireisiin. Kuitenkin monialaisen palveluntarpeen yhteen kietoutuneisuus edellyttäisi myös sosiaalihuollon mukaan ottamista. Huomioitavaa on myös tilanteet, joissa palveluntarvetta ei yksinkertaisesti voida arvioida tai tunnistaa. Rosengard ja muut nostavat esiin Watsonin ja muiden (2003) katsauksen. Watson ja muut (2003, s. 11) viittaavat henkilöihin, jotka ovat vaarassa jäädä palvelujen ulkopuolelle. Kyse ei ole siitä, etteikö henkilöä tavoitettaisi vaan siitä, ettei hän yksinkertaisesti ole palvelujen piirissä. Se, miten algoritmit kykenevät tunnistamaan monialaista palveluntarvetta, on käsitellyssä tutkielman kappaleessa 5. Seuraavassa kappaleessa esitellään käytetty tutkimusmenetelmä.

4 Tutkimusmenetelmänä kuvaileva kirjallisuuskatsaus

Kirjallisuuskatsaus (*review, literature review*) tutkii tehtyä tutkimusta (Salminen, 2011, s. 2–5). Kirjallisuuskatsausten kirjo on vaihteleva, ja niiden menetelmälliseen kehittämiseen on ryhdytty kiinnittämään enemmän huomiota (Kangasniemi ja muut, 2013, s. 291). Toisaalta kehittäminen itsessään on myös lisännyt kirjallisuuskatsauksiin liittyvien käsitteiden vakiintumattomuutta ja jäsentymättömyyttä (Kangasniemi ja muut, 2013, s. 293; Arksey & O'Malley, 2005, s. 19–20). Tyhjentävää määritelmää kirjallisuuskatsauksille ei siis todennäköisesti voi antaa. Yleisesti kirjallisuuskatsaus kuvataan Salmisen (2011, s. 2–5) mukaan tutkimustekniikkana, joka kokoaa yhteen tutkimusten tuloksia mutta myös arvioi niitä analyttisesti. Kirjallisuuskatsaus ei siten ole lähdeluettelolla koristeltu selvitys tai raportti, eikä myöskään artikkeleista koottu tiivistelmä, vaan itsenäinen tutkimusmetodi, joka on toistettavissa. Lähtökohtaisesti kirjallisuuskatsauksen tarkoitus ei kuitenkaan ole tarjota uutta tietoa, vaan esitellä aikaisemmin saatuja tuloksia (Gregory & Denniss, 2018, s. 893).

Kirjallisuuskatsaus voidaan toteuttaa useilla eri tavoilla ja eri perustein (Salminen, 2011, s. 2–5). Gregory ja Denissin (2018, s. 893–984) mukaan yksi tapa on jakaa kirjallisuuskatsaukset kuvaileviin sekä systemaattisiin kirjallisuuskatsauksiin. Systemaattisesta kirjallisuudesta voidaan johtaa meta-analyysi, joka yhdistää kirjallisuuskatsaukseen myös tilastoanalytiikkaa. Salminen (2011, s. 38) puolestaan jaottelee kuvailevan kirjallisuuskatsauksen narratiiviseen sekä integroivaan. Kangasniemen ja muiden (2013, s. 293–294) viittaamana, suomeksi käytetään käsitteitä kuvaileva, perinteinen, laadullinen tai narratiivinen kirjallisuuskatsaus.

Tämä tutkielma edustaa kuvailevaa kirjallisuuskatsausta. Gregoryn ja Denissin (2018, s. 893–894) mukaan kuvaileva kirjallisuuskatsaus (*narrative review*) tunnetaan myös perinteisenä eli traditionaalisenä kirjallisuuskatsauksena (*traditional review*). Kuvaileva kirjallisuuskatsaus pyrkii analysoimaan ja kokoaa yhteen aikaisempaa kirjallisuutta, mutta sen toteutukseen ei ole systemaattista tai tarkkarajaista menettelytapaa.

Vastaavasti systemaattinen kirjallisuuskatsaus perustuu tarkasti määrittelyyn toteutukseen, jonka ansiosta sen tuloksia pidetään usein luotettavampina kuin kuvailevan kirjallisuuskatsauksen.

Edellä kuvattu ei tarkoita, etteikö kuvaileva kirjallisuuskatsaus voisi antaa luotettavaa tietoa. Kuitenkin onnistunut menetelmän käyttö edellyttää tutkijalta perehtymistä sekä kuvailevan kirjallisuuskatsauksen erityispiirteiden tuntemusta (Kangasniemi ja muut, 2013, s. 298; ks. myös Green ja muut, 2006, s. 103). Näihin kuvailevan kirjallisuuskatsauksen erityispiirteisiin palataan tutkielman kappaleessa 4.1. Tietyissä tapauksissa kuvaileva kirjallisuuskatsaus voi olla myös soveltuvampi menetelmä kuin systemaattinen kirjallisuuskatsaus (Murphy, 2012, s. 89). Tämänkaltaisen tilanne voi olla esimerkiksi historialliseen, menneeseen tietoon suuntautuvassa tutkimusasetelmassa, kuten kronologisessa katsauksessa, joka kuvaa tietyn teorian kehitystä (Carnwell & Daly, 2001, s. 61–62). Kuvailevan kirjallisuuskatsauksen vahvuus on, että se voi antaa tietoa myös hyvin hajanaisista tai pirstaleisista aiheista (Kangasniemi ja muut, 2013, s. 295). Lisäksi kuvaileva kirjallisuuskatsaus voi auttaa ajantasaistamaan tietoa (Green ja muun, 2006, s. 103). Parhaimmillaan kuvailevan kirjallisuuskatsauksen avulla pystytään luomaan monipuolinen kuvaus käsiteltävästä aiheesta (Salminen, 2011, s. 7).

Vaikka systemaattinen ja kuvaileva kirjallisuuskatsaus saatetaan laittaa vastakkain, ne voivat toimia myös toisiaan täydentävinä (Kangasniemi ja muut, 2013, s. 299). Gregoryn ja Dennissin (2018, s. 893–895) mukaan kuvailevan ja systemaattisen kirjallisuuskatsauksen välillä on paitsi eroavaisuuksia, myös yhtäläisyyksiä. Niin systemaattinen kuin kuvaileva kirjallisuuskatsaus alkavat aiheen määrittelyllä sekä rajauksella. Olennaista on tunnistaa paitsi tutkijan oma mielenkiinto, myös tutkimukselle suunnattu kohderyhmä sekä aikaisemman tutkimuskirjallisuuden riittävyys. Kokematon tutkija saattaa valita liian lavean aiheen, jolloin käsiteltävä tutkimuskirjallisuus paisuu liian suureksi, tai liian kapean aiheen, josta aikaisempaa kirjallisuutta ei löydy riittävästi. Tämän lisäksi myös kirjallisuuden etsiminen ja uudelleen etsiminen erilaisia rajoituksia hyödyntäen on olennainen osa niin kuvailevan kuin systemaattisen

kirjallisuuskatsauksen toteutusta. Taulukko 2 vertaa systemaattisen ja kuvailevan kirjallisuuskatsauksen välisiä ominaisuuksia Gregoryn ja Dennisin (2018, s. 895) mukaan.

Taulukko 2. Kirjallisuuskatsauksien vertailua (Gregory ja Dennis, 2018).

Ominaisuus	Kuvaileva kirjallisuuskatsaus	Systemaattinen kirjallisuuskatsaus
Tutkimuskysymys	väljempi	rajatumpi
Aineiston lähde	ei yleensä määritelty	kattava, selkeä hakumenettely
Aineiston valinta	mahdollisesti puolueellisesti valittu	kriteereihin perustuva, puolueeton
Aineiston arviointi	vaihteleva	tiukka, kriittinen
Synteesi	usein kvalitatiivinen	tavallisesti kvantitatiivinen
Johtopäätökset	voidaan mahdollisesti laatia näyttöön perustuen	yleensä näyttöön perustuvat

4.1 Erityispiirteet osana tutkimusprosessia

Kangasniemi ja muut (2013, s. 294-295) nimeävät kuvailevan kirjallisuuskatsauksen erityispiirteiksi kuvailun, aineistolähtöisyyden ja ymmärtämisen. He jäsentävät kuvailevan kirjallisuuskatsauksen prosessin neljään eri vaiheeseen, joita ovat tutkimuskysymyksen asettaminen, aineiston valinta, kuvailun rakentaminen ja toteutetun tuloksen tarkasteleminen. Em. vaiheet etenevät myös päällekkäin ja limittäisinä toisiinsa nähden. Kuitenkin tutkimuskysymys toimii koko prosessia ohjaavana tekijänä, ja jokaisen katsaukseen valitun tutkimuksen kohdalla tarkastellaan sen merkitystä tutkimuskysymykseen vastaamisessa. Vaikka lähtökohtaisesti tutkimuskysymyksen on oltava riittävän täsmällinen syvällisen käsittelyn mahdollistamiseksi, Kangasniemen ja muiden (2013, s. 295) mukaan kuvailevan kirjallisuuskatsauksen tutkimuskysymys voi olla myös laeasti muotoiltu, jolloin se sallii ilmiön tarkastelun monista eri näkökulmista. Kokonaistavoitteena on muodostaa riittävän tarkka, mutta sopivan väljästi asetettu tutkimuskysymys.

Kangasniemen ja muiden (2013, s. 294–296) mukaan, ymmärrys kuvailevan kirjallisuuskatsaukseen tarvittavan aineiston soveltuvuudesta ja riittävydestä tarkentuu tutkimusprosessin edetessä. Joskus aineiston valinta ja analyysi käydään läpi samanaikaisesti. Aineiston valintaprosessi voidaan tehdä eksplisiittisesti tai implisiittisesti. Aineiston eksplisiittisessä valinnassa kirjallisuuden valinnan vaiheet kuvataan tarkemmin, systemaattista kirjallisuuskatsausta mallintaen. Tällöinkin kuvailevan kirjallisuuskatsauksen aineiston keruussa painotetaan kuitenkin kirjallisuuden sisältöä, ei ennalta asetettujen ehtojen noudattamista. Kangasniemen ja työryhmän (2013, s. 295; Rother 2007 mukaan) viittaamana implisiittinen aineiston valinta tarkoittaa, että aineisto kerätään tieteellisistä lähteistä, mutta käytettyjä tietokantoja tai valittuja sisäänotto- ja arviointikriteerejä ei kuvata tarkemmin. He viittaavat Carnwellin ja Dalyn (2001, s. 59-61) kuvaamaan, jonka mukaan implisiittisesti valitun aineiston relevanttius ja pätevyys tuodaan esille raporttiin rakennetun argumentaation keinoin, jolloin lähteiden valintaa ja lähdekritiikkiä arvioidaan aineiston käsittelyn puitteissa.

4.1.1 Kuvailevan kirjallisuuskatsauksen argumentaatio

Argumentaatio on yksi kuvailevan kirjallisuuskatsauksen erityispiirteistä ja vahvuuksista (Kangasniemi, 2013, s. 299; Rodhes, 2011 mukaan). Argumentointi on taito, johon sisältyy väite, sen perustelut sekä taustaoletukset. Tieteellinen teksti koostuu useista argumenteista, jotka rakentavat tekstin pääväitettä. Onnistuneen argumentin perustelut ja taustaoletukset ovat riittävän hyväksyttäviä. Hyväksyttävyyttä voi tuoda perustelujen ja taustaoletusten aikaisempi tunnettavuus, relevanttius ja alkuperäisen lähteen luotettavuus. Myös konteksti kuvaus eli olosuhteiden määrittely, joissa väite pitää paikkansa, lisää argumentin hyväksyttävyyttä. Onnistunut argumentti ei välittömästi muutu katteettomaksi, vaikka vastaan löytyisi vasta-argumentti (Kakkuri-Knuuttila & Halonen, 1999. s. 63-70)

Kuvailevan kirjallisuuskatsauksen argumentaatio rakentuu eri tavoin. Carnwellin ja Dalyn (2001, s. 59–62) mukaan se voi sisältää katsaukseen valittujen artikkeleiden metodologisen, empiirisen ja teoreettisen taustan tarkastelun. Tutkija voi tarkastella, onko artikkelissa esitettyjen väitteiden takana konsensusta sekä millaisia vasta-argumentteja esitettyihin väitteisiin liittyy. Tilanteissa, joissa tunnettuja vastaväitteitä ei ole, tutkija voi myös kysyä itseltään millaisia argumentteja heikentäviä näkökulmia väitteeseen voi liittyä. Vastaus voi perustua teoreettiseen taustaan tai kokemukseen. Kangasniemi ja muut (2013, s. 299; esim. Rumrill & Fitzgerald 2001 mukaan) kirjoittavat subjektiivisesta, yleistämiseen pyrkivästä induktiivisesta päättelystä ja sen ohjaaman tiedon tavoittelusta, jolloin aineisto- ja ilmiölähtöisesti voidaan tuottaa uusia näkökulmia valittuun tutkimusaiheeseen. Keskeinen ero kuvailevan ja systemaattisen kirjallisuuskatsauksen välillä on nimenomaan induktiivisuus ja sen myötä rakentuva tieto, mikä altistaa subjektiivisuutensa vuoksi myös virheellisille tulkinnoille.

Myös kriittisyys voi olla tapa rakentaa argumentaatiota. Aineiston käsittelyssä Gregory ja Denniss (2018, s. 893–895) peräänkuuluttavat kriittisyyttä. Tarkoitus ei ole vain tiivistää aikaisempia tuloksia, vaan myös keskustella niistä kriittisesti. Tämä voi auttaa tunnistamaan tiedon ja metodologian rajoitteita. Vaikka kirjallisuuskatsauksen varsinainen tarkoitus ei ole luoda uutta tietoa, voi nimenomaan onnistunut analyysi tuoda uusia näkökulmia aihepiiriä käsittelevään tutkimuskirjallisuuteen. Sajavaara (2018, s. 259–260) kuitenkin korostaa, että kritiikki itsessään ei ole riittävä, vaan huomio palautuu esitettyihin perusteluihin ja argumentaatioon. Pyrkimys ei ole esittää tutkimustietoa yksityiskohtaisesti, vaan suhteessa käsiteltävään tutkimusongelmaan.

Toisaalta kriittisyyden merkityksestä kuvailevassa kirjallisuuskatsauksessa on myös vastakkaisia mielipiteitä. Salminen (2011, s. 7–8) viittaa Greenin, Johnsonin ja Adamsin (2006, s. 103) toteamaan, jonka mukaan kriittisyys ei ole kuvailevan kirjallisuuskatsauksen oletusarvo. Tähän voisi kuitenkin lisätä myös Greenin ja työryhmän huomion kuitenkin siitä, että kuvailevan kirjallisuuskatsauksen toteutuksen tulisi olla niin puolueeton kuin mahdollista (2006, s. 106). Salminen (2011, s. 7; ks. myös

Green, 2006, s. 103) huomauttaa, että kuvailevaan kirjallisuuskatsaukseen läpikäyty aineisto voi myös olla kovin suppea. Esimerkiksi päätoimittajan tai vierailevan kirjoittajan laatima kirjoitus, jota taustoitetaan tutkimusmateriaalilla ja joka tukee lehdessä käsiteltävää teemaa, voidaan joissain yhteyksissä esittää kuvailevana kirjallisuuskatsauksena. Vastaavasti kommentoivalla otteella kirjoitettu kirjallisuuskatsaus pyrkii herättämään keskustelua, mutta muodostaa puolueellisen lopputuloksen, jos kirjoittaja ei ole rajannut lähdemateriaalia objektiivisesti.

4.1.2 Eettiset periaatteet

Edellä kuvatusta voidaan johtaa ajatus luotettavuudesta ja eettisyydestä yhtenä kuvailevan kirjallisuuskatsauksen ja sen toteutuksen erityispiirteenä. Hirsjärven (2018, s. 23–24) mukaan eettisyys tutkimuksessa tarkoittaa hyvän tieteellisen käytännön noudattamista. Tämä tarkoittaa mm. tiedeyhteisön tunnustamien toimintatapojen noudattamista, kuten rehellisyyttä ja yleistä huolellisuutta tutkimustyössä sekä sen suunnittelussa. Tulosten julkistamisessa noudatetaan avoimuutta ja tutkimusryhmän jäsenten sidonnaisuuksiin liittyvät seikat tuodaan esiin.

Kangasniemi ja muut (2013, s. 292) tuovat esiin eettiset näkökulmat, jotka liittyvät kuvailevan kirjallisuuskatsauksen tutkimuskysymyksen muotoiluun ja tutkimusetiikan noudattamiseen kaikissa prosessin vaiheissa. Myös luotettavuuteen liittyviä kysymyksiä tulee arvioida katsaukseen valitun kirjallisuuden sekä käytetyn argumentaation konteksteissa. Huolimatta tutkimusprosessin eri vaiheiden limittäisyydestä, luotettavuuden näkökulmasta tutkimustyön tulisi säilyä johdonmukaisena. Kuvailevan kirjallisuuskatsaukseen aineistolähtöisyys ja siihen liittyvä, osin subjektiivinen ja yleistävään pyrkivä päättely rajoittavat myös tuotetun tiedon laajempaa hyödyntämistä (Kangasniemi ja muut, 2013, s. 298–299), mikä tulee huomioida tuloksia esitettäessä.

Eettisyys nousee esiin myös kuvailevan kirjallisuuskatsauksen rakentamassa kuvauksessa. Kangasniemen ja muiden (2013, s. 297) mukaan kuvailevan kirjallisuuskatsauksen viimeinen ja päättävä vaihe on tulosten tarkastelu. Tuloksia tarkastellaan sisällöllisistä ja metodologisista, sekä myös tutkimuksen etiikan ja luotettavuuden arvioinnin näkökulmista. Pohdinta saaduista tuloksista on olennainen osa kirjallisuuskatsauksen toteutusta.

4.2 Tutkimusprosessin kuvaus

Tämän tutkielman aiheen rajaus alkoi syksyllä 2020 pro gradu -tutkielmaan liittyvän seminaarityöskentelyn käynnistyessä. Varsinaisen tutkimuskysymyksen muodostaminen edellytti aiheeseen ja kirjallisuuteen syventymistä, jotta aikaisemmin kuvatuista tekoälyn, algoritmiperusteisen profiloinnin ja monialaisen palveluntarpeen laajoista teoreettisesta ja käsitteellisestä viitekehystä pystyttiin muodostamaan käsiteltävissä olevat tutkimuskysymykset:

- 1) Miten algoritmeja on hyödynnetty monialaisen palveluntarpeen tunnistamisessa?
- 2) Mitä etuja ja haittoja algoritmiperusteisessa palveluntarpeen tunnistamisessa on?

Tutkielman on toteutettu kuvailevana kirjallisuuskatsauksena, joka on luonteeltaan yleiskatsaus. Kuten aikaisemmin viitattu Gregory ja Dennis (2018) kirjoittavat synonyymina perinteisestä kirjallisuuskatsauksesta. Kuvaileva eli narratiivinen yleiskatsaus on toimituksellista tai kommentoivaa kirjallisuuskatsausta laajempi prosessi, joka tiivistää aikaisemman tutkimuksen ja tarjoaa ytimekkään ja johdonmukaisen yhteenvedon (Salminen, 2011, s. 7). Sen riittävä laajuus sekä toisaalta aikaisemmin kuvattu menetelmän väljyys ja sallivuus tutkimuskysymysten asettamisessa tukevat myös tämän tutkielman tavoitetta, mahdollistamalla yleiskuvauksen luomisen sekä toisaalta sosiaali- ja terveyspalveluissa tapahtuvaan algoritmiperusteiseen profilointiin liittyvien etujen ja haittojen punnitsemisen. Lisäksi kuvailevan kirjallisuuskatsauksen sallima kuvailu tukee tutkimuskysymystä siitä, miten algoritmeja on hyödynnetty

monialaisen palveluntarpeen tunnistamisessa. Kuvailevan kirjallisuuskatsauksen soveltamista tässä tutkielmassa tukee myös aikaisempi tutkimustyö. Esimerkiksi D’Hotman ja Loh (2020, s. 1, s. 6) esittelivät kuvailevassa kirjallisuuskatsauksessaan itsemurhariskiä ennakoivia, tekoälyperusteisia sovelluksia ja niiden käyttökelpoisuutta itsemurhien ehkäisyssä. Zhang, Meng ja Cai (2021) hyödynsivät kuvailevan kirjallisuuskatsauksen tutkimuskirjallisuuden ajantasaistavaa luonnetta ja kuvasivat, kuinka tekoäly on kehittynyt keuhkosyövän varhaisessa tunnistamisessa.

Aineiston keruu ja valinta on tehty *eksplisiittisesti*. Eksplisiittinen aineiston valinta mukailee systemaattista kirjallisuuskatsausta, noudattamalla ennalta määriteltyjä tietokanta-, aika- ja kielirajauksia, jotka esitellään lukijalle. Tässä yhteydessä on kuitenkin toistettava Gregoryn ja Dennissin (2018, s. 893–894) toteamus, jonka mukaan kuvailevan kirjallisuuskatsauksen toteutukseen ei ole tarkkarajaista menettelytapaa, toisin kuin systemaattiseen kirjallisuuskatsaukseen. Hakukriteerien määrittämisestä huolimatta, kuvailevan kirjallisuuskatsauksen eksplisiittinen aineistonhaku ei siis ole verrannollinen systemaattisen kirjallisuuskatsauksen toteutukseen. Kuvailevan kirjallisuuskatsauksen eksplisiittinen aineistonhaku sallii esimerkiksi ennalta määritellyistä hakukriteereistä poikkeamisen, mikäli se on relevanttia tutkimuskysymykseen vastaamisen kannalta (Kangasniemi, 2013, s. 296; Green ym. 2006 mukaan). Tämä toteutui myös tässä tutkielmassa: aikaisempaan kirjallisuuteen perustuvista hakusanoista sekä ennalta tehdyistä koehauista huolimatta, myös tämän tutkielman hakusanat täsmentyivät aineistonkeruun prosessin aikana. Osin tämä tapahtui varmasti siksi, että kirjallisuudesta puuttuu konsensus monialaisen palveluntarpeen määrittelystä, mikä on suurin este kirjallisuuskatsauksen hakuparametrejä arvioitaessa (Rosengard ja muut, 2007, s. 4). Lisäksi eksplisiittisen tietokantahaun lisäksi, tutkimusaineistoon valittiin mukaan manuaalisella käsihaulla löydettyjä artikkeleita.

Vaikka yleisesti hakukriteereistä poikkeamisen katsotaan lisäävän subjektiivisuutta, on subjektiivisuus jo lähtökohtaisesti sisään rakennettuna kuvailevaan

kirjallisuuskatsaukseen (Green, 2006, s. 111). Tämän perusteella voidaan todeta, ettei hakukriteereistä poikkeaminen ei muuta tämän tutkielman hyödyntämiskelpoisuutta. Lisäksi Kangasniemen ja muiden (s. 2013, s. 294–295) mukaan ymmärrys kirjallisuuskatsaukseen tarvittavan aineiston soveltuvuudesta ja riittävydestä tarkentuu tutkimusprosessin edetessä, jolloin aineiston valinta sekä analyysi tapahtuvat osin samanaikaisesti. Tästä näkökulmasta katsottuna, hakuparametrien tarkentuminen tutkielmaprosessin aikana tai aineiston täydentäminen manuaalisesti eivät ole varsinaisia puutteita. Voidaan todeta, että kuvailevan kirjallisuuskatsauksen eksplisiittinen aineistonhaku tuo tähän tutkielmaan toistettavuutta ja läpinäkyvyyttä, mutta ei vastaa systemaattisen kirjallisuuskatsauksen laajuutta. Myöskään lähtökohtaisesti kuvailevan kirjallisuuskatsauksen tarkoituksena ei ole toimia esimerkiksi poliittishallinnollisen päätöksenteon tukena (Green ja muut, 2006, s. 104; ks. myös Salminen, 2011, s. 7). Kuitenkin Salmisen (2007, s. 7–8) mukaan kuvaileva kirjallisuuskatsaus, joka toteutetaan yleiskatsauksena, mahdollistaa johtopäätökset, joihin voi sisältyä myös tieteellistä kriittistä ajattelua. Kokonaisuudessaan kuvailevan kirjallisuuskatsauksen avulla on mahdollista ajantasaistaa tutkimustietoa sekä luoda perustaa jatkotutkimuskohteille, jolloin se soveltuu myös tämän tutkielman tavoitteisiin.

4.2.1 Aineiston keruu

Aineiston kerättiin Academic Search Elite- (EBSCO), ScienceDirect- ja Google Scholar -tietokannoista. Valittujen tietokantojen valintaperusteena toimi niiden laajuus ja poikkitieteellisyys. Vaikka Google Scholaria on kritisoitu mm. vähäisen toistettavuuden vuoksi (Giustini & Boulons, 2013) se valittiin mukaan helppokäyttöisyyden vuoksi – pro gradu -tutkielman edustaessa opinnäytetyötä, aineiston tuli olla saatavissa kohtuullisin voimavaroin. Koska tutkielmaa taustoittavassa teoriakuvauksessa havaittiin suomalaisen kirjallisuuden vähyys, ei aineistoa haettu suomen kielellä tai kotimaisista tietokannoista.

Hakusanojen määrittelyssä hyödynnettiin aikaisempaa kirjallisuutta. Esimerkiksi Kivipellon ja muiden (2019, s. 28) laatimassa, palveluntarpeen tunnistamista

kansainvälisesti kartoittavassa kirjallisuuskatsauksessa esiintyi laajasti eri hakusanoja mm. monialaiseen palveluntarpeeseen, palvelujen suurkäyttöön sekä toistuvaan palvelunkäyttöön liittyen. Lisäksi Kivipelto työryhmineen oli katsauksessaan määritellyt palveluihin, tunnistamiseen ja tunnistamisen työkaluihin liittyviä hakusanoja. Toisaalta Kivipellon ja työryhmän kartoituksessa oli mukana kaikki mahdolliset palveluntarpeen tunnistamisen mallit ja keinot, ml. kyselylomakkeet ja haastattelututkimukset, mikä poikkesi tämän tutkielman tavoitteista. Lopulta tämän tutkielman hakusanat määräytyivätkin aikaisemman kirjallisuuden lisäksi tutkimuskysymysten perusteella, jolloin hakusanoissa korostettiin nimenomaan algoritmeja ja monialaista palveluntarvetta eri ilmaisuin. Hakusanoja täydennettiin myös tunnistamisen ja ennakkoinnin käsitteillä sekä hyötyä/haittoja kuvaavien termien avulla. Useamman hakusanan käyttö oli välttämätöntä, sillä tutkimuskysymys oli laeva ja tutkimuskysymyksiä oli kaksi. Taulukko 3 listaa lopullisessa aineiston haussa käytetyt hakusanat. Kirjallisuuskatsauksen aineistonhaku on dokumentoitu hakupäiväkirjaan (liite 1). Manuaalisen käsihaun kautta valitut artikkelit (3 kpl) löydettiin testihakujen perusteella sekä sellaisten artikkeleiden lähdeviittauksista, jotka eivät suoraan soveltuneet katsauksen aineistoon, mutta joiden alkuperäismateriaali oli tutkimuskysymysten kannalta kiinnostava.

Monialaista palveluntarvetta kuvaavat hakusanat	Tekoälyä kuvaavat hakusanat	Tunnistamista kuvaavat hakusanat	Hyötyjä/haittoja kuvaavat hakusanat
<i>complex/chronic/multiple health/social service/care needs</i>	<i>algorithm</i>	<i>profile prediction model(s) predict identify predictive analytics discover</i>	<i>advantages dis-</i>

Taulukko 3. Käytetyt hakusanat.

4.2.2 Aineiston valinta

Kirjallisuuskatsaukseen valittujen artikkelien keskeinen valintaperuste oli artikkelien osuvuus tutkimuskysymyksen kannalta sekä artikkelien saatavuus. Mukaan valittiin vain maksuttomia, koko tekstin artikkeleita, jotka oli kirjoitettu englanniksi. Tiivistelmän tai otsikon piti viestiä tekoälystä/koneoppimisesta/algoritmeista sekä palveluntarpeen tunnistamisesta, jonka jälkeen artikkeli otettiin lähempään tarkasteluun. Monialaiseen palveluntarpeeseen ei tarvinnut viitata otsikossa tai tiivistelmässä, sillä kuten aikaisemmin tutkielmassa todettu, ei ole olemassa yksiselitteistä monialaisen palveluntarpeen viitekehystä. Artikkeleihin syventyessä niiden tuli kuitenkin viestiä monialaisesta palveluntarpeesta, esimerkiksi viittaamalla artikkelissa esiintyvän kohderyhmän toistuvaan, kalliiseen, korkeariskiseen, haastavaan tai kompleksiseen palvelujen käyttöön, tarpeeseen, tunnistamiseen tai monisairastavuuteen. Vertaisarvoituja artikkeleita suosittiin, mutta tämä ei ollut ehdoton edellytys. Artikkelit, joissa viitattiin muihin palveluohjauksen malleihin tekoälyn sijaan, suljettiin pois. Artikkelit, joiden lähtökohta oli tietojärjestelmätieteinen, rajattiin pois. Taulukko 4 tiivistää aineiston valintakriteerit.

Sisäänottokriteerit	Poissulkukriteerit
Kontekstina sosiaali- ja terveyspalvelut	Kontekstina liiketoimintaympäristö, esim. pankki- ja vakuutussektori, markkinointi.
Palveluntarpeen tunnistaminen ja ennakointi tekoälyperusteisesti	Muu palveluntarpeen tunnistaminen ja ennakointi
Viittaus monialaiseen, kalliiseen, toistuvaan tai kompleksiseen palveluntarpeeseen.	Ei viittausta monialaiseen palveluntarpeeseen.
Vertaisarvioitu tutkimus tai muu tieteellisessä julkaisussa julkaistu tutkimusartikkeli tai vertaisarvioidussa tieteellisessä lehdessä julkaistu kommenttipuheenvuoro/kolumni	Kirjallisuuskatsaus, kirja-arvostelu tai kommenttipuheenvuoro, jota ei ole julkaistu vertaisarvioidussa tieteellisessä lehdessä.
Julkaisukielenä englanti	Julkaisukielenä muu kieli
Julkaisu vuosi 2014-2023.	Julkaistu vuosien 2014-2023 ulkopuolella.
Koko tekstin artikkeli saatavissa	Koko tekstin artikkeli ei ole saatavissa

Taulukko 4. Valintakriteerit.

Lopullisessa kirjallisuuskatsauksessa oli mukana 12 artikkelia. Näistä kolme (3) valittiin mukaan käsihaussa ja loput tietokantahaulla. Liite 2 esittelee katsaukseen valitun aineiston. Lisäksi katsaukseen valitut artikkelit on merkitty tutkielman lähdeluetteloon *-merkillä. Aineiston laadun osalta todetaan, että kaksi (2) artikkeleista ei ollut vertaisarvioituja. Huomioitava kuitenkin on, ettei tutkielman sisällä valitun aineiston tarkempaa laadullista arviointia, kuten näytön asteen analyysiä. Lähes kaikki valitut 12 artikkelia kuvasivat tutkimuskysymystä ennalta määriteltyjen kriteerien mukaisesti. Ainoastaan Malgierin & Niklaksen (2020) artikkelissa varsinainen viittaus algoritmiperusteiseen profilointiin nimenomaan monialaisen palveluntarpeen kontekstissa puuttui, mutta artikkeli valittiin mukaan, sillä se kuvasi haavoittuviin ryhmiin (ml. ikääntyneet, monisairaat) kohdistuvaa tekoälyperusteista datan käyttöä. Tutkimusasetelma oli laillisuusnäkökulmasta, mutta artikkeli huomioi nimenomaan algoritmiperusteisen profiloinnin käsitteen.

4.2.3 Aineiston analyysi

Tutkimusaineisto on käsitelty temaattisen analyysin keinoin. Lisäksi aineistosta nousseita tutkimustuloksia on tarkasteltu suhteessa tässä tutkielmassa aikaisemmin kuvattuihin teoreettisiin lähtökohtiin, mikä edustaa kuvailevan kirjallisuuskatsauksen argumentaatiota tarkastelemalla, löytyykö aineistosta nousseille havainnoille tukea. Tätä peilaamista on tehty erityisesti tutkielman yhteenvedossa (luku 6).

Temaattinen analyysi muistuttaa sisällönanalyysiä, jossa aineistoa luokitellaan ja teemoitetaan eri tavoin ja tavoittein, tutkimuskysymyksen ohjaamana. Temaattista analyysiä on myös pidetty yhtenä sisällönanalyysin toteutustapana. (Tuomi & Sarajärvi, 2018, s. 105, s. 140-141) Kuitenkin Braun ja Clarke (2006, s. 4–6) esittelevät temaattisen analyysin itsenäisenä, joustavana analyysimenetelmänä. Aineistosta tunnistetaan erilaisia tutkimuskysymykseen vastaavia teemoja, jotka raportoidaan.

Tuomen ja Sarajärven (2018, s. 140-141) mukaan temaattinen analyysi ja sisällönanalyysi etenevät samankaltaisin vaiheihin, jo molemmissa lähestymistavoissa pääpaino on aineistossa sekä tutkimuskysymyksessä. Ensin aineistoon tutustutaan ja siitä tehdään muistiinpanoja, jonka jälkeen kiinnostavat ilmaistut pelkistetään ja kootaan (koodataan) kiinnostaviksi kokonaisuuksiksi. Sisällönanalyysissa ilmaisujen pelkistäminen vieään kuitenkin pidemmälle, kategorisoimalla ylä- ja alaluokkia, kun taas temaattisessa analyysissä pelkistetty aineisto järjestetään teemoihin ja mahdollisesti myös niiden välisiin suhteisiin. Braun ja Clarke (2006, s. 8) kuitenkin muistuttavat, ettei temaattisen analyysin lähtökohtana toimi mikään tietty teoria. Vastaavasti siinä missä sisällönanalyysin tulokset esitetään usein taulukkomuodossa, kuvataan temaattisen analyysin aineisto temaattisena karttana, joka on muodoltaan ajatuskarttaa muistuttava (Tuomi ja Sarajärvi, 2018, s. 140–141). Se kokoaa yhteen aineistosta nousseet teemat, mutta on vähemmän yksityiskohtainen ja hierarkkinen kuin sisällönanalyysissä tehty koodaus (Braun ja Clarke, 2006, s. 30, s. 40, s. 41). Keskeistä on myös, etteivät teemat emergoidu aineistosta itsestään, vaan ne syntyvät tutkijan henkilökohtaisen, aktiivisen analyysin ja tulkinnan tuloksena (Tuomi ja Sarajärvi, 2018, s. 140-141). Tästä näkökulmasta katsottuna, temaattinen analyysi on siten myös tulkinnallisuutta lisäävä. Tämän tutkielman kannalta, temaattiset kartat mahdollistavat yleiskuvan luomisen ja ilmiölähtöisen tarkastelun. Toisaalta temaattisten karttojen tulkinnallisuus ja aineistolähtöisyys soveltuvat myös kuvailevan kirjallisuuskatsauksen perusolemukseen.

Aineiston analyysi alkoi hyväksytyt tutkimusaineiston lukemisella ja muistiinpanojen kirjoittamisella. Tämän jälkeen aineisto koodattiin. Braunin ja Clarken (2006, s. 17–18) mukaan temaattisessa analyysissä koodaus tarkoittaa, että aineistoa organisoidaan kiinnostaviin ryhmiin, joista voidaan myöhemmin johtaa potentiaalisia teemoja. Taulukko 5 listaa tämän tutkielman aineiston analyysin pelkistetyt havainnot ja niistä johdetut kokonaisuudet. Näiden perusteella on laadittu temaattinen kartta. Temaattinen kartta on kuvattu kappaleessa 5. Huomioitava on, että joku toinen tutkija olisi voinut löytää aineistosta erilaisia teemoja, mikä näkyisi erilaisina tutkimustuloksina. Tässäkin mielessä huomioitava on siten kuvailevan kirjallisuuskatsauksen subjektiivisuus.

Pelkistetty havainto aineistosta	Koodattu kokonaisuus
<p>-Korkeariskisten potilaiden tunnistaminen algoritmin avulla, sitten intervention ohjaus ammattilaisen toimesta (Cohen ym., 2014)</p> <p>- Koneoppimisalgoritmit voivat määrittää, kuka on palvelujen suurkäyttäjä, luokittelu pelkästään määrän perusteella ei ole riittävä (Goodman ym., 2021)</p> <p>- Algoritmit voivat tunnistaa yksittäisiä sairauksia tai eri sairauksien välisiä yhteyksiä. (Wu ym., 2018).</p> <p>- Ikääntyneiden asumispalveluissa ilmenevien sairauksien tunnistaminen, ei vaadi uuden aineiston keräämistä (Lind ym., 2020)</p> <p>- Ennen algoritmeja käytettiin väestön terveydentilan kuvaamiseen, nyt tietoa voi analysoida potilaskohtaisesti (Dorr ym. 2021)</p> <p>- Algoritmit voivat olla tarkempia kuin ammattilaisen intuitio, mutta niiden toiminta on epäselvää. (Dorr ym., 2021)</p> <p>- Algoritmit voivat tunnistaa varhain lapset ja nuoret, jotka ovat riskissä kasvavalle palveluntarpeelle tai alttiita tietyille sairauksille. (Stewart ym., 2015; Hammond ym., 2019)</p> <p>- Algoritmit voivat ohjata resurssien allokointia (Wu ym. 2018; Stewart ym., 2015)</p> <p>- Algoritmien avulla voidaan ennakoita monisairaiden asiakkaiden joutumista takaisin sairaalahoitoon 30 päivän sisällä. (Mohanty ym., 2015) sekä sairaalassaolon kestoa (Abd-Elrazek ym., 2021).</p> <p>- Algoritmit voivat hyödyntää kaikkea ja toisaalta vain annettua dataa. Otannan edustavuuden haasteet myös RCT-tutkimuksissa (Gianfrancesco ym., 2018).</p> <p>- Jos useita eri diagnooseja on useissa eri paikoissa, algoritmien voi olla vaikea tunnistaa näitä asiakkaita (Gianfrancesco ym., 2018)</p> <p>- Koneoppimismallien valinnan haasteet, (Abd-Elrazek ym., 2021). Haavoittuvimmat ryhmät huomioitava (Malgieri ym. 2020)</p>	<p>- Kalliin palvelunkäytön tunnistaminen algoritmin avulla</p> <p>- Algoritmit ja ammattilaiset toisiaan täydentävinä</p> <p>- Algoritmit paljon palveluja tarvitsevien teoreettisen viitekehysten täydentämisessä</p> <p>-Algoritmit eri sairauksien yhteenliittymien tunnistajana.</p> <p>- Algoritmit ikääntyneiden/väestön terveydentilan kuvaamisessa</p> <p>- Olemassa oleva tieto käyttöön sosiaali- ja terveyspalveluissa</p> <p>- Yksilöllisen terveydentilan ennakointi</p> <p>-Algoritmi voi olla intuitiota tarkempi</p> <p>-Kehittämistyön tarve, keskeneräisyys</p> <p>-Algoritmit palveluntarpeen ja riskitekijöiden tunnistamisessa varhaislapsuudesta alkaen</p> <p>-Algoritmit resurssien käytön tehostajina</p> <p>-Algoritmit ja palveluntarpeen tiheyden ennakointi</p> <p>- Tietyt sosioekonomiset ryhmät voivat olla aliedustettuina aineistossa. Pitäisi ensin päästä palveluihin, jotta löytyisi terveystietodataa.</p> <p>- Otannan vaikeudet eivät koske vain algoritmeja</p> <p>- Nimenomaan monialaisen palveluntarpeen tunnistaminen voi olla vaikeaa.</p> <p>- Mallit eivät ole universaaleja. Eettisyys</p>

Taulukko 5. Aineiston koodaus eli ryhmittely.

5 Tulokset

5.1 Miten algoritmeja on hyödynnetty monialaisen palveluntarpeen tunnistamisessa?

Tutkimusaineiston perusteella, algoritmiperusteista palveluntarpeen tunnistamista on hyödynnetty lasten ja nuorten mielenterveysongelmien (Stewart ja muut, 2019), lasten ja nuorten ylipainon (Hammond ja muut, 2018), aikuisiän diabeteksen (Wu ja muut, 2018), ensihoidon palvelujen käytön (Goodman ja muut, 2021) sekä ikääntyneiden asiakkaiden (Lind ja muut, 2020) kohdalla. Näiden kaikkien osalta aineistossa viitattiin kompleksiseen, yhteiskunnallisesti kalliiseen tai monialaiseen palveluntarpeeseen. Lisäksi algoritmien avulla on ennakoitu sairaalassaolon kestoa (Abd-Elrazek ja muut, 2021) sekä tunnistettu asiakkaan riski joutua takaisin sairaalahoitoon 30 päivän sisällä (Mohanty ja muut, 2022), viittaamalla näiden olevan merkittäviä syitä kalliille ja monialaiselle palveluntarpeelle. Diagnoosiryhmää tai palveluntarpeen kestoa määrittämättä, algoritmeja hyödynnettiin myös sellaisten monisairaiden potilaiden tunnistamiseksi, joilla katsottiin olevan korkea riski kasvavalle ja kalliille palveluntarpeelle tulevaisuudessa (Cohen ja muut, 2014). Lisäksi viitattiin tarkemmin määrittelemättä monialaisen palveluntarpeen omaavien asiakkaiden tunnistamiseen (*patients with complex health needs*) perusterveydenhuollossa, algoritmien avulla tapahtuvan riskiluokittelun avulla (Dorr ja muut, 2021). Algoritmeja käytettiin myös seulomaan ja tunnistamaan lastensuojeluun tulleista yhteydenotoista henkilöt, joilla voi olla merkittävin palveluntarve (Chouldechova ja muut, 2018).

Monialaisen palveluntarpeen määrittely siten vaihteli tutkimusaineistossa, mikä on linjassa tässä tutkielmassa aikaisemmin kuvatun kanssa siitä, ettei monialaiselle palveluntarpeelle ei ole yhtä selittävää määritelmää. Tutkimusaineistossa algoritmeja käytettiin myös käsitteellistämään monialainen palveluntarve. Goodmanin ja muiden tutkimuksessa (2021, s. 57–63) algoritmien avulla rakennettiin teoreettinen viitekehys

paljon päivystyspalveluita käyttäville henkilöille ja heidän tunnistamiselleen. Koneoppimisalgoritmit tunnistivat ja luokittelivat sähköisen potilastietokannan aineiston perusteella toistuvasti päivystykseen hakeutuvat henkilöt joko päivityskäyntien määrän tai palvelun käytön luonteen perusteella. Tulosten mukaan algoritmi, joka sääntöpohjaisesti tunnistasi ja luokitteli palvelunkäytön yksinomaan käyntien määrän perusteella, ei onnistunut tunnistamaan kaikkia paljon päivystyspalveluita käyttäviä asiakkaita. Palvelujen käytön määrä vaihteli asiakkaiden välillä, eivätkä algoritmit aina onnistuneet luokittelemaan asiakkaita sopiviin ryhmiin. Vastaavasti algoritmi, joka ohjelmoitiin huomioimaan pelkän määräperusteisen palveluntarpeen sijaan useita biopsykososiaalisia tekijöitä, onnistui luokittelemaan samankaltaiset asiakkaat samankaltaisiin ryhmiin, kuitenkin siten, että ryhmien välillä oli selkeät erot. Goodmanin ja muiden mukaan (2021) tämä vahvisti käsitystä siitä, ettei pelkkä määräperusteinen palveluntarpeen tunnistaminen ole riittävä paljon palveluita tarvitsevien tunnistamiseksi, mikä on huomioitava sosiaali- ja terveyspalvelujen arjessa sekä tekoälyperusteisia ohjelmistoja kehitettäessä.

Tutkimusaineistossa toistui monialaisen palveluntarpeen algoritmiperusteisen tunnistamisen vaihtelevat toteutustavat, mistä voidaan johtaa yksi teema tutkielman temaattiseen karttaan (kuvio 3). Osa malleista perustui ei-sääntöpohjaiseen tekoälyyn (ks. esim. Mohanty ja muut, 2022, s.22) ja osa sääntöpohjaiseen tekoälyyn (ks. esim. Abd-Elrazek ja muut, 2021, s. 3698). Toteutustavasta riippumatta, käytännössä kaikissa tutkimusaineiston artikkeleiden johtopäätöksissä tuotiin ilmi, että kehittämistyötä tekoälyperusteisten ohjelmistojen suhteen tarvitaan edelleen. Osassa aineistosta algoritmiperusteisen palveluntarpeen tunnistamisen toteutus perustui oikeaan potilasdataan ja kliinisiin asiakastilanteisiin (ks. esim. Cohen ja muut., 2014; Lind ja muut., 2020; Dorr ja muut., 2021). Mukana oli myös tutkimuksia, jossa palveluntarvetta tunnistava algoritmi oli kehittämis- ja pilotointivaiheessa (ks. esim. Mohanty ja muut., 2022). Aineistosta nousseet havainnot kehittämistyön tarpeesta sekä tekoälyperusteisten ohjelmistojen keskeneräisyydestä on johdettu teemoina tutkielman temaattiseen karttaan (kuvio 3). Vastaavasti Stewartin ja muiden (2019, s. 4–8)

tutkimuksessa algoritmin ohjelmointi perustui valmiiseen, sosiaali- ja terveystaloudissa jo käytössä olevaan kyselylomakkeeseen, joka toimi myös itsenäisenä palveluntarpeen tunnistamisen työkaluna. Kyselylomakkeesta johdettujen tietojen sekä tilastollisen ja klinisen mallintamisen perusteella luotiin mittaristo, jonka perusteella algoritmi ohjelmoitiin luokittelemaan lapset ja nuorten palveluntarvetta kuvaaviin riskitasoihin, sähköisistä potilastietokannoista saatavan informaation perusteella.

Toistuvana teemana aineistosta erottui myös algoritmiperusteisen palveluntarpeen tunnistamisen vaihtelevat tavoitteet. Vaihtelevat tavoitteet on nimetty temaattiseen karttaan erillisinä teemoina. Yhtenä aineistosta erottuvana algoritmiperusteisen tunnistamisen tavoitteena oli ennakoita asiakkaan riskiä tulevaisuudessa lisääntyvälle kalliille tai monialaiselle palveluntarpeelle (Cohen ym., 2014). Algoritmien avulla pyrittiin esimerkiksi ennakoimaan lapsen riskiä ja alttiutta ylipainoon ensimmäisten elinvuosien aikana kerättyjen tietojen perusteella, tavoitteena ehkäistä monisairastavuutta ja kasvavaa palveluntarvetta aikuisiällä (Hammond muut, 2019, s. 2-13). Algoritmeja käytettiin myös tunnistamaan toistuvaa palvelujen käyttöä: Mohanty ja muut (2022, s. 1–2; ks. myös Abd-Elrazek ja muut, 2021) kehittivät viisi (5) erilaista koneoppimiseen perustuvaa riskityökalua, jotka ennakoivat ikääntyneen potilaan joutumista takaisin sairaalahoitoon seuraavan 30-päivän sisällä.

Yhtenä tavoitteena aineistossa erottui myös algoritmien hyödyntäminen terveydentilan kuvaamisessa. Lindin muiden (2020) tutkimuksessa algoritmeja käytettiin kuvaamaan laitoshoidossa asuvien ikäihmisten terveydentilaa, jotta heidän monialainen palveluntarpeensa (*complex health needs*) tulisi paremmin ymmärretyksi. Lisäksi algoritmeja käytettiin myös tunnistamaan tietyn sairauden yhteyttä monialaiseen palveluntarpeeseen. Yhdysvaltoihin sijoittuvassa tutkimuksessaan Wu ja muut (2018, s. 85–86) avasivat, kuinka päihteiden väärinkäyttö sekä mielenterveysongelmat heikentävät väestön terveyttä ja lisäävät terveydenhuollon kustannuksia, mutta näiden sairauksien yhteyttä monialaiseen palveluntarpeeseen ei ole todettu. Vastaavasti diabetes on Yhdysvalloissa kaikista yleisin, yhteiskunnallisesti erittäin kallis sairaus ja

myös yleisin kuolinsyy. Wu työryhmineen kehitti algoritmin tunnistamaan sähköisestä potilastietorekisteristä aikuiset, joilla oli korkean riskin diabetes. Tämän jälkeen joukosta poimittiin asiakkaat, joilla ilmeni myös mielenterveys- tai päihdeongelmia. Menetelmä katsottiin uudelleenlaiseksi tavaksi tunnistaa erilaisten sairauksien yhteenliittymiä.

Tutkimusaineistosta nousi toistuvasti esiin algoritmien ja terveydenhuollon ammattilaisten yhteistyö monialaisen palveluntarpeen tunnistamiseksi. Cohenin ja muiden (2014, s. 1–8) tutkimuksessa algoritmit täydensivät terveydenhoitoalan ammattilaisten työtä. Tavoitteena oli ensin algoritmin avulla tunnistaa potilaat, joilla on korkea riski kalliiden palveluiden käytölle. Käytössä oli terveydenhuollon sähköiset potilastiedot 2010, joiden perusteella algoritmit ennakoivat potilaan riskiä tarvita kalliita palveluita seuraavana vuonna 2011. Algoritmien suorittaman tunnistamisen jälkeen, terveydenhoitoalan ammattilaiset valitsivat algoritmien tunnistamista potilaista heidät, joiden katsottiin hyötyvän hoitointerventioista. Tutkimuksensa johtopäätöksinä Cohen ja muut (2014) esittivät, että hoitoonohjauksen malli, joka yhdistää niin algoritmiperusteisen tunnistamisen kuin terveydenhuollon asiantuntijoiden arvion, on vaikuttava tapa edistää monisairaiden asiakkaiden pääsyä palvelujen piiriin. Yhtäältä aineistosta ilmeni ilmi myös, että juuri monialaisen palveluntarpeen tunnistaminen algoritmiperusteisesti voi olla vaikeaa: Gianfrancescon ja muiden (2019, s. 3) mukaan on havaittu, että tekoälyperusteisten järjestelmien voi olla haastavaa tunnistaa asiakkaat, joilla on useita eri hoitopaikkoja. Tämä johdattelee tulosten tarkastelun algoritmiperusteiseen profilointiin liittyvien hyötyjen ja haittojen teemoihin.

5.2 Algoritmiperusteisen palveluntarpeen tunnistamisen edut ja haitat

Tutkimusaineiston artikkeleissa todettiin algoritmiperusteisen palveluntarpeen tunnistamisen potentiaali sosiaali- ja terveydenhuollon kustannusten säästämässä sekä hoidon parantumisessa (ks. esim. Mohanty ja muut 2021; Lind ja muut, 2020; Gianfrancesco ja muut, 2018). Tutkimusaineistossa kuvattiin tähän potentiaaliin liittyviä

perusteita, yksityiskohtia, joita voidaan tässä kuvailevaa kirjallisuuskatsausta edustavassa tutkielmassa soveltaa myös eräänlaisina argumentteina, jotka kuvaavat tekoälyperusteisen palveluntarpeen tunnistamisen hyötyjä. Näistä havainnoista on johdettu teemoja tutkielman temaattiseen karttaan (kuvio 3).

Yksi algoritmiperusteisen palveluntarpeen tunnistamisen hyötynä toistuva teemana oli terveydenhuollon resurssien käytön tehostuminen (ks. esim. Stewart ja muut, 2015; Chouldechova ym.) sekä hoitoon liittyvän päätöksenteon parantuminen (Lind ja muut, 2020; Stewart ja muut, 2019). Sosiaali- ja terveydenhuollossa koneoppimisalgoritmien päätöksentekoa edistävä vaikutus syntyy koneoppimisen kyvystä analysoida ja yhteensovittaa tietokannoista peräisin olevaa dataa, joka yhdistettynä diagnoosityökaluihin tarjoaa sote-alan asiantuntijoille kohdennettua ja ajantasaista tietoa hoitoon liittyvän päätöksenteon tueksi (Gianfrancescon ja muut, 2019, s. 2). Lisäksi Dorrin ja muiden (2021, s. 7) tutkimuksessa algoritmit ennakoivat asiakkaan hoidon tarpeita ja siihen liittyviä kustannuksia paremmin kuin asiantuntijuuteen perustuva intuitio. Tämän katsottiin olevan merkityksellistä erityisesti monialaisen palveluntarpeen tunnistamisessa.

Lindin ja muiden (2020) mukaan algoritmien tunnistamien terveystilojen myötä voidaan tilastollisten menetelmien avulla luokitella sairauksien esiintyvyyttä mm. iän ja sukupuolen mukaan, mikä tuo uudenlaista tietoa sairauksien esiintyvyydestä. Hyötynä on se, että algoritmiperusteinen palveluntarpeen tunnistaminen hyödyntää käytössä olevaa sosiaali- ja terveydenhuollon dataa: uutta aineistoa ei tarvitse kerätä, ja toisaalta kaikki olemassa oleva tieto saadaan käyttöön. Lisäksi sähköisistä asiakas- ja potilasrekistereistä johdettu terveystieto on tarkempaa, kuin asiakkaan itsensä raportoima tieto. Tämä mahdollistaa tosiasiallisen kuvauksen henkilön tai väestöryhmän terveydentilasta. Koneoppimisalgoritmien voivat myös analysoida sellaista määrää dataa, johon ihminen ei kykenisi (Gianfrancesco ja muut, 2019, s. 2). Tutkimusaineistosta nousi esiin koneoppimisalgoritmien tarkkuus. Koneoppimisalgoritmit tunnistivat lapsen riskiä

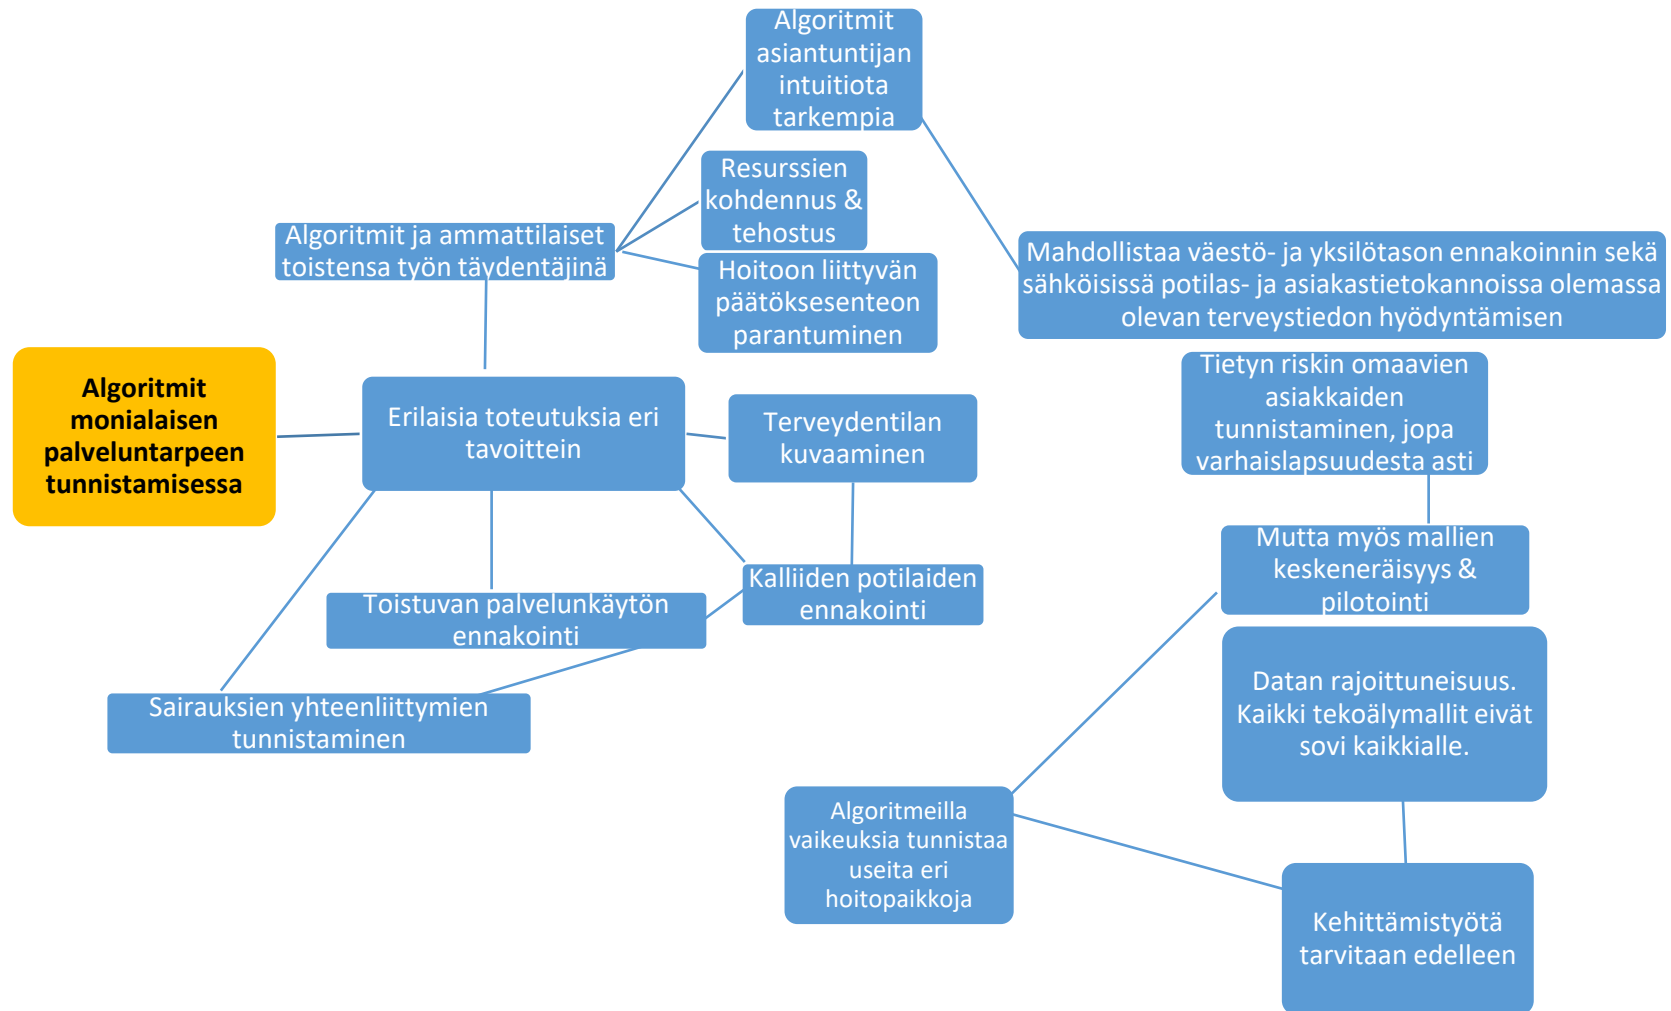
ylipainoon yhtä tarkasti tai jopa paremmin, kuin aikaisemmat perinteiset ennakoititutkimukset (Hammond, muut, 2019, s. 13).

Toisaalta tutkimusaineistossa toistuvana teemana ilmeni myös koneoppimisalgoritmien tekemät virheet (ks. esim. Chouldechova ja muut, 2018). Gianfrancescon ja muiden (2019, s. 2, s. 5–6) mukaan aikaisemmissa tutkimuksissa on havaittu, että algoritmien käyttö esimerkiksi mainoksissa tai oikeudellisessa päätöksenteossa voi edistää sosioekonomista eriytymistä. Tätä riskiä tulisi arvioida myös sosiaali- ja terveystaloudissa nyt. Vaikka algoritmien vahvuus on, että ne voivat hyödyntää kaikkea käytettävissä olevaa dataa, on tämä samalla niiden heikkous – ne hyödyntävät vain ja ainoastaan käytettävissä olevaa dataa. Gianfrancescon ja muiden (2019: ks. myös Mohanty ja muut, 2022; Chouldechova ja muut, 2018) mukaan sosiaali- ja terveystaloudissa tämä tarkoittaa, että algoritmin tulisi kyetä huomioimaan myös erilaiset etniset syntyperät sekä erilaiset sosioekonomiset ryhmät. Huomiota tulee siten kiinnittää siihen, miten algoritmi on ohjelmoitu tunnistamaan palveluntarvetta. Aineistossa toistui havainto, että koneoppimisalgoritmien tehokkuus on tärkeää, mutta niin on myös eettisyys. Haavoittuvassa asemassa olevat henkilöt, kuten monisairaat ja vanhuksien, ovat haavoittuvia myös heihin liittyvän datan käytön näkökulmasta (Malgieri & Niklas, 2020).

Lisäksi Gianfrancesco ja muut (2019, s. 5–8) korostavat, että huomiota on myös kiinnitettävä siihen, kuka puuttuu: ketä tai mitä asiakasryhmää algoritmin ohjelmoinnissa ei korosteta riittävästi. Toisaalta Abd-Elrazek ja muut (2021) käyttivät tutkimuksessaan sairaalassaolon pitkittymisen ennakoimiseen erilaisia koneoppimismalleja todeten, etteivät kaikki mallit sopineet kaikkiin tilanteisiin. Heidän mukaansa yhdessä organisaatiossa kehitettyä algoritmia ei voida soveltaa toisessa organisaatiossa, minkä myös Gianfrancesco ja muut (2019) toivat ilmi. Tämän perusteella pyrkimys ei siten ole universaalien palveluntarpeen tunnistamisen mallien rakentamiseen, mikä on nostettu yhtenä teemana myös tämän tutkielman temaattiseen karttaan (kuvio 3). Algoritmien kehittämiseen liittyvän otannan riittävyys voi olla

ongelma myös tavanomaisissa verrokkiryhmäkontrolloiduissa tutkimuksissa, joita kuitenkin tutkimuksessa ja päätöksenteossa hyödynnetään, joten kyseessä ei ole ongelma, josta voitaisiin kritisoida vain tekoälyä tai algoritmeja (Gianfrancesco ja muut, 2019, s. 4).

Yhtäältä algoritmi ei sellaisenaan sovi päätöksenteon perustaksi ilman kliinisen asiantuntijan arviota. Näin on erityisesti lasten ja nuorten palvelujen kontekstissa. Lasten ja nuorten palveluntarpeen arvioinnin osalta tarvitaan eri ammattilaisten välistä yhteistyötä ja harkintaa siitä, soveltuuko algoritmi ylipäätään tietyn lapsen palveluntarpeen arviointiin. Myös algoritmin tuloksiin tulee suhtautua kriittisesti ja arvioida, kuvaavatko ne tosiasiallisesti lapsen tilaa. Lapsen ja hänen läheistensä tulee voida osallistua hoitoa koskevaan päätöksentekoprosessiin algoritmista riippumatta. Lapsi ei myöskään saa jäädä ilman palveluita, vaikka algoritmi ennakoisi, ettei riskiä kohonneelle palveluntarpeelle ole. (Stewart, 2019, s. 8–10)



Kuvio 3. Temaattinen kartta

6 Yhteenveto ja tulkinta

Tämän sosiaali- ja terveyshallintotieteellisen pro gradu -tutkielman tutkimustehtävänä oli selvittää, miten algoritmeja on hyödynnetty monialaisen palveluntarpeen tunnistamisessa sekä millaisia etuja ja haittoja tähän liittyy. Tutkimuskysymyksiin vastattiin kuvailevan kirjallisuuskatsauksen avulla. Tutkielman teoreettisena viitekehyksenä käsiteltiin algoritmeja sosiaali- ja terveyspalveluissa sekä monialaisen palveluntarpeen lähtökohtia. Tutkimuskysymyksiin vastaamisen lisäksi tavoitteena oli kuvata potentiaalisia jatkotutkimuskohteita. Tässä luvussa aineistosta saatuja havaintoja kootaan yhteen. Lisäksi tehdään tulkintaa tutkielmassa aikaisemmin esiteltyyn peilaten, pyrkimyksenä hyödyntää kuvailevan kirjallisuuskatsauksen argumentaatiota. Lisäksi kuten aikaisemmin viitattu, Carnwellin ja Dalyn (2013) mukaan tutkija voi tietyissä tilanteissa perustaa argumenttinsa myös kokemukseen. Tätä kokemuksellisuuteen ja näkemyksellisyyteen perustuvaa tulkintaa käytetään soveltuvin osin tutkielman tulosten yhteen kokoamisessa.

Tämän tutkielman tutkimusaineisto vahvisti käsitystä siitä, ettei monialaiselle palveluntarpeelle ole yhtä selittävää määritelmää. Toisaalta tutkimusaineisto toi esiin näkökulman, jonka mukaan algoritmeja voidaan hyödyntää nimenomaan monialaisen palveluntarpeen ja sen tunnistamisen määrittelyssä. Goodmanin ja muiden (2021) tutkimustulokset vahvistivat käsitystä siitä, ettei tämä pelkkä määräperusteinen palveluntarpeen tunnistaminen ole riittävä. Kuten tämän tutkielman alussa viitattiin, vastaaviin johtopäätöksiin on päätyttyä myös Yli-Katajisto (2019) ja Hauswaldt (2013). Tästä näkökulmasta tulkittuna, tekoäly voi myös auttaa käsitteellisen ja teoreettisen jäsentymisen muodostumisessa, mikä voisi itsessään edistää monialaisen palveluntarpeen tunnistamista ja asiakkaiden palvelujen piiriin pääsemistä – ymmärrys monialaisesta palveluntarpeesta kokonaisuutena voisi edistää monia palveluja tarvitsevien asiakkaiden kohtaamista.

Aineistosta nousi esiin tilanteita, joissa algoritmeja on hyödynnetty tunnistamaan tai ennakoimaan monialaista palveluntarvetta. Tutkimustuloksissa ja temaattisessa kartassa (kuvio 3) kuvatut teemat algoritmien kyvystä tunnistaa esim. korkean riskin omaavia asiakkaita tai eri sairauksien yhteenliittymiä voidaan pitää hyödyllisinä, kun kartoitetaan keinoja monialaisen palveluntarpeen omaavien asiakkaiden tunnistamiseksi ja siten palveluihin pääsyn edistämiseksi. Tutkimusaineistoissa nousi esiin myös monialaisen palveluntarpeen tunnistaminen palveluntarpeen tiheyden, ei yksinomaan palvelujen käytön määrän perusteella (ks. esim. Mohanty ja muut, 2022). Tämä tuki tutkielman alussa esitetyn Hauswaldtin ja muiden (2013) näkemystä, jossa tarkastelun ei tule rajoittua vain palvelujen käytön määrään, vaan myös käyntien väliseen aikaan.

Mielenkiintoista oli myös se, että algoritmien tekemät havainnot olivat joissain tapauksissa hyvin linjassa aikaisempien tutkimustulosten kanssa: esimerkiksi Stewartin ja muiden (2019) tutkimuksessa algoritmit ennakoivat lapsen mielenterveyspalvelutta vastaavasti kuin aikaisempi tutkimuskirjallisuus. Tämä antaa osaltaan kuvan algoritmien toimivuudesta ja soveltuvuudesta palveluntarpeen ennakointiin. Lisäksi tutkielman alussa esitettiin näkemys siitä, että sosiaalihuollossa tapahtuva tekoälyperusteinen palveluntarpeen tunnistaminen on vielä vähäistä. Kuitenkin Stewartin ja muiden (2019, s. 4–8) tutkimuksessa algoritmi tunnisti myös sosiaalisia tekijöitä, jotka ennakoivat lasten ja nuorten kasvavaa tarvetta mielenterveyspalveluille. Algoritmi tunnisti myös sosiaalisia tekijöitä, kuten läheisten ystävien puutteen, mielenterveyspalvelujen tarvetta ennakoivaksi. Tämä oli linjassa aiheeseen liittyvän aikaisemman tutkimuksen kanssa siitä, että myös lasten ja nuorten monialaista palveluntarvetta ennakoivat useat tekijät.

Toisaalta aikaisemmassa tutkimuskirjallisuudessa (ks. esim. Autioniemi, 2021) on korostettu nimenomaan kontekstin merkitystä tekoälytutkimuksessa ja sen soveltamisessa. Myös tässä tutkimusaineistossa erottui se, etteivät algoritmiperusteisen tunnistamisen mallit ole universaaleja. Sovellettaessa tämän tutkielman tuloksia suomalaisiin sosiaali- ja terveyspalveluihin huomioitava on, että tutkimusaineiston alkuperämaa ei ollut Suomi ja suomalainen terveydenhuolto. Tällöin erot

palvelujärjestelmässä ja erityisesti hoitoon pääsemisessä voivat olla merkittäviäkin, mikä voi vaikuttaa myös tekoälyperusteisten mallien soveltamiseen. Vastaavaa muistutti myös Koivisto (2019) työryhmineen, joihin viitattiin aikaisemmin tässä tutkielmassa.

Algoritmien hyödyntämisen datan rajoitteet toistuivat aineistossa. Konkreettinen esimerkki, miten käytössä oleva data ohjaa algoritmin päätöksentekoa, tuli esiin Stewartin ja muiden tutkimuksessa (2019): koska vanhempia lapsia oli aineistossa enemmän, heillä oli myös enemmän mielenterveysongelmia. Toisaalta kuten aikaisemmin tutkielman tutkimustuloksia käsittelevässä osuudessa tuotiin esiin, on samankaltaisia otannan edustavuuden haasteita myös satunnaiskontrolloiduissa tutkimuksissa. Tästä näkökulmasta katsottuna, algoritmit tai niiden käyttämisen datan edustavuuden ja soveltuvuuden pulmat koskevat myös muuta tutkimustyötä. Stewartin tutkimuksessa käytössä oli standardoitu kyselylomake algoritmien ohjelmoinnin pohjana. Pohdittavana on, voisiko yksi keino algoritmiperusteisen palveluntarpeen tunnistamisen ja siihen liittyvien virhepäätelmien ehkäisemiseksi olla valmiiden kyselylomakkeiden käyttö algoritmien ohjelmoinnissa. Voisiko muutenkin terveydenhuollossa käytettävä standardoitu tutkimus- ja arviointilomake toimia algoritmin ohjelmoinnin pohjana, ja mahdollisesti itsessään vähentää algoritmeihin liittyviä virhepäätelmiä sekä ohjata algoritmien toimintaa? Tämä vie keskustelun potentiaalsiin jatkotutkimuskohteisiin, joita käsitellään lisää myöhemmin.

Toisaalta kirjallisuuskatsauksen aineistosta saadut havainnot tukivat myös tutkielman alussa kuvattua näkemystä siitä, että monialaisen palveluntarpeen omaavien henkilöiden on vaikea päästä palvelujen piiriin. Vaikka mm. dataan liittyvät rajoitteet nousevat esiin, onko väärin jättää algoritmien potentiaali hyödyntämättä, jos sen avulla voidaan tunnistaa edes pieni osa monia palveluita tarvitsevista? Tämän tutkielman teoreettisessa tietoperustassa tuotiin ilmi, että monialaisen palveluntarpeen tunnistaminen sosiaali- ja terveystaloudissa nojaa nykyisellään pitkälti asiantuntijoiden intuitioon, ja toisaalta tämän tutkielman tutkimusaineistossa Cohen työryhmineen (2021) esitti algoritmien olevan intuitiota tarkempia. Tämän perusteella kysyttynä,

ovatko algoritmit sittenkin intuitiota parempia edistämään monia palveluja tarvitsevien asiakkaiden palveluihin pääsyä? Vastaavasti Stewart työryhmineen (2019) ilmaisi asian myös toisinpäin: asiakas ei saa jäädä ilman palveluja, vaikka algoritmi ennakoisi, ettei tarvetta olisi. Tutkielman tutkimusaineistosta erottuikin eri ammattilaisen välinen yhteistyö, moniammatillisuus ja harkinta algoritmiperusteisen palveluntarpeen tunnistamisen yhteydessä. Algoritmit voivat toimia sosiaali- ja terveydenhuollon ammattilaisten työtä täydentävinä. Vastaavaan johtopäätökseen palveluntarpeen tunnistamisen malleja koskien oli päätyttyä myös teoriaosuudessa viitattu Kivipelto työryhmineen (2019).

Tutkielman alussa viitattiin myös tilanteeseen, jossa henkilön palveluntarvetta ei voida tunnistaa yksinkertaisesti siksi, ettei henkilö ole tavoitettavissa, löydettävissä, palvelujen piiriin. Kuitenkin tutkimusaineistossa Hammond ja muut (2019) ennakoivat terveystarpeita jo varhaislapsuudessa saatujen tietojen perusteella. Tämän perusteella herää ajatus mahdollisesta tulevaisuuden tilanteesta, jossa palveluntarvetta ennakoitaan jo varhaislapsuudessa saatujen tietojen perusteella: tällöin henkilöllä ei olisi mahdollisuutta tippua pois palveluista. Samaan aikaan, nimenomaan algoritmiperusteisen profiloinnin sääntelyssä todetaan, että henkilöllä on oikeus olla joutumatta algoritmiperusteisen profiloinnin kohteeksi. Millaiset mahdollisuudet henkilöllä on kieltäytyä automatisoidusta palveluntarpeen tunnistamisesta, jos palveluntarpeen ennakoitua tehtäisiin jo varhaislapsuudesta asti? Toisaalta algoritmeihin nykyajassa liitettävät haitat eivät välttämättä ole tulevaisuudessa haittoja lainkaan – joko ne saadaan korjatuksi, tai maailman muuttuessa ne arkipäiväistyvät.

Yhtäältä aineisto vahvisti myös tutkielman alussa viitattua Autioniemen (2021) käsitystä siitä, että tekoälyn soveltamiskäytäntö julkisissa palveluissa on vielä vähäistä. Osa tutkimusaineistossa kuvatuista tunnistamisen esimerkeistä oli vasta kehittämisvaiheessa. Tämän kokeiluasteen voisi itsessään tulkita algoritmiperusteisen palveluntarpeen tunnistamisen heikkoudeksi: miten varmistua siitä, ettei toivottu potentiaali paljastu tyhjäksi luuloksi? Tämä kysymys on mielenkiintoinen erityisesti siksi, että

algoritmiperusteisen palveluntarpeen tunnistamisen suora kustannushyötymekanismi jäi tutkimusaineistossa epäselväksi. Tämä tieto olisi kiinnostava, sillä monialaiseen palveluntarpeeseen on yhdistetty valtaosa julkisen terveydenhuollon kustannuksista. Tämän perusteella voidaan yhtyä Autioniemen (2021, s. 139) sekä Parviaisen ja Rantalan (2020, s. 7–8) aikaisemmin töissään sivuamaan kysymykseen, miksi juuri tekoälyn odotetaan ylivoimaisesti ratkaisevan hyvinvointiyhteiskunnan haasteet? Aineistossa toistui, kuinka algoritmiperusteinen palveluntarpeen tunnistaminen auttaa kohdentamaan terveydenhuollon resursseja. Tämän voisi tulkita todennäköisenä kustannussäästönä, samoin kuin se, että varhainen tunnistaminen keventää palveluketjun myöhäisempiä kustannuksia. Kuitenkin pohdittavana on, voisiko mikä tahansa rutiininomainen, monialaisen palveluntarpeen tunnistamisen malli tai käytäntö tuoda säästöjä? Tutkielman teoreettisessa viitekehyksessä viitatus VTV:n (2017) mukaan, Suomessa valtaosassa terveyskeskuksissa ei ole käytössä mitään tunnistamisen mallia. Yksi jatkotutkimuskohde olisikin kartoittaa, mitä etuja potentiaalisesti kalliit tekoälyinvestoinnit toisivat verrattuna siihen, että hyvinvointialueilla otettaisiin käyttöön tavanomaiset, mutta kuitenkin systemaattiset, monialaisen palveluntarpeen tunnistamisen keinot?

Laillisuusnäkökulmasta mielenkiintoista oli se, että tutkimusaineistossa viitattiin vain harvoin algoritmiperusteiseen profilointiin. Tämä on ristiriidassa tämän tutkielman alussa kuvattujen käsitteellisten valintojen kanssa. Tämä saattaa selittyä eroilla sääntelyssä. EU-lainsäädännössä profiloinnin käsite on tunnistettu, mutta osa tutkimusaineiston artikkeleista tuli Yhdysvalloista tai muualta Euroopan ulkopuolelta. Malgieri ja Niklas (2020, s. 6–7) viittasivat algoritmiperusteiseen profilointiin yhtenä automaattisen päätöksenteon erityismuotona nimenomaan EU-lainsäädännön viitekehyksessä, mutta muutoin tutkielman tutkimusaineistossa viitattiin yleisesti algoritmeihin tai koneoppimiseen. Tämä havainto on mielenkiintoinen, sillä kuten tutkielman alussa aikaisemmin viitattu, Parviainen ja Rantala (2020) kiinnittivät nimenomaan huomiota siihen, ettei tekoälyn soveltamisessa ohiteta olemassa olevaa sääntelyä. Tästä näkökulmasta tulkittuna se, ettei algoritmiperusteisesta

palveluntarpeen tunnistamisesta puhuta profiloitina, voi osin vääristää ilmiötä ja siihen liittyvien haittojen punnitsemista. Profilointiin liittyen on huomioitu ja tunnistettu se, että henkilö voi myös tästä kieltäytyä, ja että toimintaa tulee säädellä laissa.

Hallinnon ja johtamisen näkökulmasta pohdittavana on myös, ettei algoritmiperusteinen palveluntarpeen tunnistaminen (tai profilointi) saisi johtaa osaoptimointiin. Vaikka tunnistaminen on keskeistä, se ei sellaisenaan riitä. Mitä kokonaisvaltaisemmin sosiaali- ja terveydenhuollon johtamisen keinoin käsiteltäviin ilmiöihin suhtaudutaan, sitä paremmat ovat mahdollisuudet myös ilmiöiden välisten riippuvuuksien tunnistamiselle ja osaoptimoinnin välttämiseksi (Jalonen, 2010, s. 124).

Jatkotutkimuskohteet

Kuten jo aikaisemmin sivuttu, potentiaalisina jatkotutkimuskohteina voidaan nähdä arviointi- ja kyselylomakkeiden käyttö algoritmiperusteisen palveluntarpeen tunnistamisen ohjelmoinnissa ja erityisesti siihen liittyvien virhepäätelmien ehkäisyssä. Lisäksi vertailu minkä tahansa systemaattisen palveluntarpeen tunnistamisen mallin ja algoritmiperusteisen palveluntarpeen tunnistamisen välillä on potentiaalinen jatkotutkimuskohde. Tutkielman alussa viitattiin eri palveluntarpeiden väliseen yhteen kietoutuneisuuteen, joka mukailee keskinäisriippuvuuksien ja vuorovaikutussuhteiden tunnistamiseen painottuvaa kompleksisuusajattelua. Tästä näkökulmasta kiinnostava oli tapa, jolla Wu työryhmineen (2018) hyödynsi algoritmeja tunnistamaan tietyn sairauden yhteyttä monialaiseen palveluntarpeeseen. Voidaan todeta, että tämän lähestymistavan hyödyntäminen jatkotutkimuksessa voisi olla hyödyllistä, jotta monialainen palveluntarve tulisi paremmin ymmärretyksi.

Eettisyys ja luotettavuus

Tutkimuksen ja etiikan välillä on vuorovaikutuksellinen suhde. Tutkimustulokset vaikuttavat eettisiin ratkaisuihin, toisaalta etiikka vaikuttaa tutkijan työssään tekemiin

valintoihin. Tieteen etiikalla tarkoitetaan nimenomaan etiikkaa, joka ohjaa tutkijan tieteellistä työtä. Hyvän tieteellisen käytännön ohjeet antaa Tutkimuseettinen neuvottelukunta (TENK), jonka mukaan tutkimuksessa tulee noudattaa vastuullisia toimintatapoja sekä edistää rehellisyyttä tieteellisessä tutkimuksessa (Tuomi & Sarajärvi, 2018, s. 147-151).

Vastuullisuuden ja rehellisyyden periaatteet ovat toimineet myös tämän tutkielman perustana. Tutkielman luotettavuutta ja toistettavuutta on pyritty lisäämään kuvaamalla tutkielman valinnat ja prosessin vaiheet mahdollisimman läpinäkyvästi. Tämä antaa myös lukijalle mahdollisuuden arvioida tuotetun tutkielman laatua. Väistämättä kuvailevan kirjallisuuskatsauksen menetelmällinen väljyys ja temaattisen analyysin tulkinnallisuus johtavat siihen, että toinen henkilö olisi voinut valita toisin. Lopputuloksessa on siten muistettava tietty subjektiivisuus, kuten on jo aikaisemmin tässä tutkielmassa todettu. Subjektiivisuuden mahdollista vinoumaa on kuitenkin pyritty oikaisemaan asianmukaisin lähdeviittein. Vastaavasti kirjoittajan omat tulkinnat on pyritty tekemään lukijalle helposti tunnistettavaksi. Tutkielman rajoitteiden sekä myös verrattain pienen aineiston koon vuoksi, tutkielman tuloksia on hyödynnettävä ja tulkittava varovaisuuden periaatteella. Tulokset eivät ole yleistettävissä.

Lähteet

*-merkityt ovat kuvailevan kirjallisuuskatsauksen tutkimusaineistoa

*Abd-Elrazek, M.A., Eltahawi, A.A, Abd Elaziz, M.H. & Abd-Elwhab, M.N. (2021). Predicting length of stay in hospitals intensive care unit using general admission features. *Ain Shams Engineering Journal*, Vol 12 (4), s. 3961–3702. <https://doi.org/10.1016/j.asej.2021.02.018>

Autioniemi, J. (2021). Tekoäly ja hallinnon käytännöt: paluu byrokraatiaan. Teoksessa Laakkonen, M. (toim.), *Informaatioteknologian filosofia, etiikka ja digitalisoitunut yhteiskunta* (s. 139–157). Jyväskylän yliopisto. <http://urn.fi/URN:ISBN:978-951-39-8804-3>

Autioniemi, J. (2020). Tekoälyn yhteiskehittäminen julkisella sektorilla. *Hallinnon tutkimus* 39(1), s. 5–20. <https://doi.org/10.37450/ht.98075>

Arksey, H. & O`Malley, L. (2005). Scoping studies: Towards a methodological framework. *International journal of social research methodology*, Vol. 8(1), s. 19–32. <https://doi.org/10.1080/1364557032000119616>

Berk, M.L. & Monheit, A.C. (2001). The Concentration Of Health Care Expenditures, Revisited. *Health Affairs*, 20(2), s. 9–18. <https://doi.org/10.1377/hlthaff.20.2.9>

Braun, V. & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*. <http://dx.doi.org/10.1191/1478088706qp063oa>

Carnwell, R., & Daly, W. (2001). Strategies for the construction of a critical review of the literature. *Nurse Education in Practice* 1(2), s. 57–63. <https://doi.org/10.1054/nepr.2001.0008>

*Cohen C.J., Flaks-Manov, N., Low, M., Balicer, R.D & Shadmi, E. (2014). High-Risk Case Identification for Use in Comprehensive Complex Care Management. *Population Health Management*. <https://doi.org/10.1089/pop.2014.0011>

*Chouldechova, A., Putnam-Hornstein, E., Benavides-Prado, D., Fialko, O. & Vaithnathan, R. (2018). A case study of algorithm-assisted decision making in child

- maltreatment hotline screening decisions. *Proceedings of Machine Learning Research*.
 Noudettu 24.7.2022 osoitteesta
<https://proceedings.mlr.press/v81/chouldechova18a.html>
- D'Hotman D., & Loh, E. (2020). AI enabled suicide prediction tools: a qualitative narrative review. *BMJ Health Care Inform*, s. 1–10. doi:10.1136/ bmjhci-2020-100175
- *Dorr, D.A., Ross, R.L, Cohen, D., Kansagara, D., Ramsey, K., Sachdeva, B. & Weiner, J.P. (2021). Primary care practices' ability to predict future risk of expenditures and hospitalization using risk stratification and segmentation. *BMC Medical Informatics and Decision Making*, vol. 21(104). <https://doi.org/10.1186/s12911-021-01455-4>
- EOAK/3379/2018. Eduskunnan apulaisoikeusasiamies.
<https://www.oikeusasiamies.fi/r/fi/ratkaisut/-/eoar/3379/2018>
- Emani, C.K., Cullot, N. & Nicolle, C. (2015). Understandable Big Data: A survey. *Computer Science Review*, (17), s. 70–81. <https://doi.org/10.1016/j.cosrev.2015.05.002>
- European Society of Cardiology. (2021). SCORE2 risk prediction algorithms: new models to estimate 10-year risk of cardiovascular disease in Europe. *European Heart Journal*, 42, s. 2439–2454. doi:10.1093/eurheartj/ehab309
- Euroopan unionin tietosuojatyöryhmä. (2017) Suuntaviivat automatisoiduista yksittäispäätöksistä ja profiloinnista asetuksen (EU) 2016/679 täytäntöön panemiseksi. Noudettu 28.5.2022 osoitteesta
<https://tietosuoja.fi/documents/6927448/8316711/Automaattinen+p%C3%A4%C3%A4t%C3%B6ksenteko/28ae24f4-3345-4fb2-8708-c84abd8f57b0/Automaattinen+p%C3%A4%C3%A4t%C3%B6ksenteko.pdf>
- ESSO-hanke. (2016). Loppuraportti. Terveyspalveluja paljon käyttävien profilointi.
 Noudettu 8.5.2022 osoitteesta <https://www.essote.fi/tietoa-meista/hankkeet/esso-hanke/>
- Ferdous, M., Debnath, J. & Chakraborty, N.R. (2020). Machine Learning Algorithms in Healthcare: A Literature Survey. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICCCNT49239.2020.9225642>

- Gandomi, A., Haider, M. (2015). *Beyond the hype: Big data concepts, methods, and analytics*. *International Journal of Information Management*, 35(2015), s. 137–144. <https://doi.org/10.1016/j.ijinfomgt.2014.10.007>
- Garfinkel, S., Riley, G.F. & Lannacchione, V.G. (1988). High-cost users of medical care. *Health Care Financing Review*, 9(4), s. 41–52. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4192887/>
- Green, B., Johnson, C., Adams, A. (2006). Writing narrative literature reviews for peer-reviewed journals: secrets of the trade. *Journal of Chiropractic medicine*, 5(3), s. 101–117. [https://doi.org/10.1016/S0899-3467\(07\)60142-6](https://doi.org/10.1016/S0899-3467(07)60142-6)
- Gregory, A.T. & Denniss, R.A. (2018). An Introduction to Writing Narrative and Systematic Reviews — Tasks, Tips and Traps for Aspiring Authors. *Heart, Lung and Circulation* 27(7), s. 893–898. <https://doi.org/10.1016/j.hlc.2018.03.027>
- *Gianfrancesco, M., Tamang, S., Yazdany, J. & Shmajuk, G. (2018). Potential Biases in Machine Learning Algorithms Using Electronic Health Record Data. *JAMA Intern Med*. 178(11), s. 1544–1547. doi:10.1001/jamainternmed.2018.3763.
- Giustini, D. & Boulons, K.M. (2013). Google Scholar is not enough to be used alone for systematic reviews. *Online Journal of Public Health Informatics*, 5(2), <https://doi.org/10.5210%2Fojphi.v5i2.4623> .
- *Goodman, J.M., Lamson, A.L., Hylock, R.H. & Jensen, J.F (2021). Emergency Department Frequent User Subgroups: Development of an Empirical, Theory-Grounded Definition Using Population Health Data and Machine Learning. *Families, Systems, & Health*, 39(1), s. 55-65. <http://dx.doi.org/10.1037/fsh0000540>
- *Hammond, R., Athanasiadou, R., Curado, S., Aphinyanaphongs, Y., Abrams, C., Messito, M.J., Gross, R., Katzow, M., Jay, M., Razavian, N. & Elbel, B. (2019). Predicting childhood obesity using electronic health records and publicly available data. *PLOS ONE*. Noudettu 16-7-2022 osoitteesta <https://doi.org/10.1371/journal.pone.0215571>
- Haula, T. & Peltola, M. (2020). Monialainen tai kallis palvelujen käyttö Suomessa. Teoksessa: Koivisto, J. & Tiirinki, H. *Monialaisen palvelutarpeen tunnistaminen sosiaali-, terveys- ja työvoimapalveluissa* (s. 30-41). Valtioneuvoston selvitys- ja

- tutkimustoiminnan julkaisusarja. 2020:38. <http://urn.fi/URN:ISBN:978-952-287-908-08>
- Hauswaldt, J., Himmel, W. & Hummers-Pradier, E. (2013) The inter-contact interval: a new measure to define frequent attenders in primary care. *BMC Family Practice* 14(162). Noudettu 7.5.2022 osoitteesta <http://www.biomedcentral.com/1471-2296/14/162>
- Hietapakka, L., Tiirinki, H. & Sinervo, T. (2020). Monialaisen palvelutarpeen tunnistaminen sosiaali- ja terveystaloudissa Suomessa Teoksessa: Koivisto, J. & Tiirinki, H. *Monialaisen palvelutarpeen tunnistaminen sosiaali-, terveys- ja työvoimataloudissa* (s. 41-60) Valtioneuvoston selvitys- ja tutkimustoiminnan julkaisusarja. 2020:38. <http://urn.fi/URN:ISBN:978-952-287-908-08>.
- Hirsjärvi, S. (2018). Tieteelliselle tutkimustyölle asetetut vaatimukset. Teoksessa *Tutki ja kirjoita*. Hirsjärvi, S., Remes, P., & Sajavaara P. (s. 18–27). Tammi.
- Hujala, A. & Lammintakanen, J. (2018) Keitä ja millaisia ”paljon palveluja tarvitsevat yhteisasiakkaat” ovat? Teoksessa *Paljon sote-palveluja tarvitsevat ihmiset keskiöön* (s. 16–20). Kunnallisan alan kehittämiskeskityön julkaisu. Noudettu 1.5.2022 osoitteesta <https://kaks.fi/wp-content/uploads/2018/01/paljon-sote-palveluja-tarvitsevat-ihmiset-keskioon.pdf>
- Innokylä. (2022, 26.huhtikuuta). Monialaisen palvelutarpeen ennakointi tekoälyn avulla - kansallinen kehittämisspilotti ikäihmisten asiakasryhmää koskien (MAITE). Noudettu 8.5.2022 osoitteesta <https://innokyla.fi/fi/kokonaisuus/monialaisen-palvelutarpeen-ennakointi-tekoalyn-avulla-kansallinen-kehittamispilotti>
- Isoherranen, K. (2012). Uhka vai mahdollisuus – moniammatillista yhteistyötä kehittämässä. Akateeminen väitöskirja. Helsingin yliopisto. <http://urn.fi/URN:ISBN:978-952-10-7664-0>
- Jalonen, H. (2010). Hyvinvointipalvelujen johtaminen kompleksisuusteoreettisessa tulkintakehyksessä. *Hallinnon tutkimus*, 29(2), 111-133.
- James, J. (2013). “Health Policy Brief: Patient Engagement,” *Health Affairs*. Noudettu 7.5.2022 <https://www.healthaffairs.org/doi/10.1377/hpb20130214.898775/full/>
- Jones, S.S., Heaton, P., Rudin, R. & Schneider, E. (2012). Unraveling the IT Productivity

- Paradox — Lessons for Health Care. *The New England Journal of Medicine* 336(24).
<http://dx.doi.org/10.1056/NEJMp1204980>
- Kakkuri-Knuuttila, M.L & Halonen, I. (1999) Argumenttiansalyysi ja hyvän argumentin ehdot. Teoksessa Kakkuri-Knuuttila, M.L (toim). *Argumentti ja kritiikki – lukemisen, keskustelun ja vakuuttamisen taidot*. (s. 60–113). Gaudeamus.
- Kangasniemi, M., Pietilä, A-M., Utriainen, K., Jääskeläinen, P., Ahonen, S-M., & Liikanen, E. (2013). Kuvaileva kirjallisuuskatsaus: eteneminen tutkimuskysymyksestä jäsennettyyn tietoon. *Hoitotiede*, 25 (4), s. 291–301.
- Kapiainen, S., Seppälä, T., Häkkinen, U., Lauharanta, J., Roine, R. & Korppi-Tommola, M. (2010). Johdanto. Teoksessa *Pääkaupunkiseudun erittäin kalliit potilaat* (s. 4–6). Terveyden ja hyvinvoinnin laitos. <https://urn.fi/URN:NBN:fi-fe201205085276>
- Kelleher, J.D. (2020). *Syväoppiminen*. Teoksessa *Kuinka tekoäly toimii*. Terra Gognita.
- Koivisto J. & Tiirinki H. (2020). Yhteenveto. Teoksessa: Koivisto, J. & Tiirinki, H. *Monialaisen palvelutarpeen tunnistaminen sosiaali-, terveys- ja työvoimapalveluissa* (s. 86-96). Valtioneuvoston selvitys- ja tutkimustoiminnan julkaisusarja. <http://urn.fi/URN:ISBN:978-952-287-908-08>
- Kivipelto, M., Suhonen, M., Koivisto, J., Tiirinki, M. & Miikki, R. (2019). Monialaisia palveluja tarvitsevien tunnistamisen ja ennakoinnin mallit – kartoittava kansainvälinen katsaus. Terveyden ja hyvinvoinnin laitos. <http://urn.fi/URN:ISBN:978-952-343-445-5>
- Kivelä, K., Elo, S., Kääriäinen, M. (2018). Frequent attenders in primary health care: A concept analysis. *International Journal of Nursing Studies*. 86, s. 115-124
<https://doi.org/10.1016/j.ijnurstu.2018.06.003>
- Kuziemski, M. & Misuraca, G.(2020). AI governance in the public sector: Three tales from the frontiers of automated decision-making in democratic settings. *Telecommunications Policy* 44(6), s. 2–13.
<https://doi.org/10.1016/j.telpol.2020.101976>
- Laki potilaan asemasta ja oikeuksista (785/1992).
<https://www.finlex.fi/fi/laki/ajantasa/1992/19920785>.
- Laki sosiaali- ja terveydenhuollon asiakastietojen sähköisestä käsittelystä (784/2021).

- <https://www.finlex.fi/fi/laki/alkup/2021/20210784>
- Laki sosiaalihuollon asiakkaan asemasta ja oikeuksista (2000/812).
- <https://finlex.fi/fi/laki/ajantasa/2000/20000812>
- Laki sosiaali- ja terveydenhuollon järjestämisestä (612/2021).
- <https://www.finlex.fi/fi/laki/alkup/2021/20210612>
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). *Deep learning*. *Nature*, (521), s. 436–444.
doi:10.1038/nature14539
- Lexico. (2022a). *Artificial intelligence*. UK Dictionary. Oxford University. Noudettu 26.3.2022 osoitteesta https://www.lexico.com/definition/artificial_intelligence
- Lexico. (2022b). *Algorithm*. UK Dictionary. Oxford University. Noudettu 10.4.2022 osoitteesta <https://www.lexico.com/definition/algorithm>
- Lexico. (2022c). *Big data*. UK Dictionary. Noudettu 10.4.2022 osoitteesta https://www.lexico.com/definition/big_data
- Leskelä, R.L, Komssi, V., Sandström, S., Pikkujämsä, S., Haverinen, A., Olli, S.L., Ylitalo-Katajisto, K. (2013). Paljon sosiaali- ja terveystalvveluja käyttävät asukkaat Oulussa. *Suomen Lääkärilehti* 48(68), s. 3163 – 3169. Saatavilla osoitteesta <https://www.laakarilehti.fi/lehdet/?year=2013&magazine=388236> [Rajattu pääsy]
- *Lind, K.E., Raban. M.Z., Brett, L., Jorgensen, M., Georgious, A., Westbrook, J.I. (2020). Measuring the prevalence of 60 health conditions in older Australians in residential aged care with electronic health records: a retrospective dynamic cohort study. *Population Health Metrics*, 18(25).
<https://doi.org/10.1186/s12963-020-00234-z>
- *Malgieri, G. & Niklas, J. (2020) Vulnerable data subjects. *Computer Law & Security Review*, 37, s. 1–16. <https://doi.org/10.1016/j.clsr.2020.105415>
- Makridakis, S. (2017). The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*, 90 (2017), 46–60.
<https://doi.org/10.1016/j.futures.2017.03.006>
- Matterland, A. (2003). Määrän kultti. Teoksessa *Informaatioyhteiskunnan historia* (s.10–28). Vastapaino Oy.

- *Mohanty, S.D., Lekan, D., McCoy T.P., Jenkins, M. & Manda, P. (2021). Machine learning for predicting readmission risk among the frail: Explainable AI for healthcare. *Patterns* 3(1). <https://doi.org/10.1016/j.patter.2021.100395>
- Moore, L., Deehan, A., Seed, P., Jones, R. (2009). Characteristics of frequent attenders in an emergency department: analysis of 1-year attendance data. *Emergency Medicine Journal* (29), 263–267. doi:10.1136/emj.2008.059428
- Murphy, C.M. (2012). Writing on an Effective Review Article. *Journal of Medical Toxicology*, (8), s. 89–90. doi 10.1007/s13181-012-0234-2
- Muurinen, S., & Mäntyranta, T. (n.d). Asiakasvastaava-toiminta pitkäaikaissairauksien terveyshyötymallissa. Sosiaali- ja terveysministeriö. Noudettu 8.5.2022 osoitteesta https://stm.fi/documents/1271139/1427058/get_file.pdf/2a2a9f1a-8751-42b6-a0f5-ad92ff87e6a2
- Mäntylä, N., Karjalainen, V., Korhonen, N., Siikavirta, K., Wenander, H., Annola, V. (2022). Virkavastuu ja palveluautomaatio. Teoksessa Mäntylä, N., Karjalainen, V., Korhonen, N., Siikavirta, K., Wenander, H., Annola, V. *Virkavastuu julkishallinnon muuttuvassa toimintaympäristössä*. (s. 118–141). Valtioneuvoston selvitys- ja tutkimustoiminnan julkaisusarja (2022:14). <https://urn.fi/URN:ISBN:978-952-383-237-4>
- Mönkkönen, K. (2007) Vuorovaikutus: dialoginen asiakastyö. Edita Prima Oy.
- Ngiam, K.Y & Khor, W.I. (2019). Big data and machine learning algorithms for health-care delivery. *The Lancet Oncol* (20), s. 262–273.
- Niiranen, V., & Lammintakanen, J., (2011). Hallintotieteen rajapinnoilla – sosiaalihallintotieteen ja terveyshallintotieteen tutkimuksen alan ja kohteen näkökulmia. Teoksessa Virtanen, T., Ahonen, P., Syväjärvi, A., Vartiainen, P., Vartola, J., Vuori, J. (toim.) *Suomalainen hallinnon tutkimus – mistä, mitä, minne?* (s. 113–149).
- Oikeusministeriö. (2020). Arviomuistio hallinnon automaattiseen päätöksentekoon liittyvistä yleislainsäädännön sääntelytarpeista. Oikeusministeriön julkaisuja 2020:14. s. 1-68. <http://urn.fi/URN:ISBN:978-952-259-878-3>

- Oikeusministeriö. (2022). Automaattista päätöksentekoa koskevan hallinnon yleislainsäädännön valmistelu. Noudettu 28.5.2022 osoitteesta <https://oikeusministerio.fi/hanke?tunnus=OM021:00/2020>
- Oksman, E. (2017). Parempi Arki. Loppuraportti. Noudettu 7.5.2022 osoitteesta <https://pikassos.fi/aineistot/send/170-parempi-arki/1055-parempi-arki-hankkeen-loppuraportti>
- Omaolo.fi. Palvelut. Oirearviot. Noudettu 8.5.2022 osoitteesta <https://www.omaolo.fi/palvelut/oirearviot>.
- Panch, T., Szolovits, P. & Atun, R. (2018). Artificial intelligence, machine learning and health systems. *Journal of Global Health* 8(2), 1–8. Noudettu 26.3.2022 osoitteesta <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6199467/pdf/jogh-08-020303.pdf>
- Parviainen, J. & Rantala, J. (2020). Ennakoiva analytiikka ja tekoälyn etiikka: Miten ennakoivat teknologiat taipuvat hallintajärjestelmäksi? *Futura* 39(1), 61–70. Noudettu 26.3.2022 osoitteesta https://www.researchgate.net/publication/340342402_Ennakoiva_analytiikka_ja_tekoalyn_etiikka_Miten_ennakoivat_teknologiat_taipuvat_hallintajarjestelmaksi_Predictive_analytics_and_AI_ethics_How_AI_technologies_turn_into_a_new_regime
- Perusluskivaliokunta. PeVL 78/2018 vp. https://www.eduskunta.fi/FI/vaski/Lausunto/Sivut/PeVL_78+2018.aspx
- Perustuslakivaliokunta. PeVL 62/2018 vp. https://www.eduskunta.fi/FI/vaski/Lausunto/Sivut/PeVL_62+2018.aspx
- Puustinen, A. & Jalonen, H. (2020). Kompleksisuusajattelu – ymmärtämistä edistävä uusi lähestymistapa vai vanhaa viiniä uudessa pullossa? Teoksessa Vartiainen, P. & Raisio, H. (toim). *Johtaminen kompleksisessa maailmassa*. Gaudeamus.
- Ragupathi, W. & Ragupathi, V. (2014). Big data analytics in healthcare: promise and potential. *Health Information Science and Systems*, 2(3), s. 2–10. <https://doi.org/10.1186/2047-2501-2-3>
- Raisoft Oy. Tiedon käsittely ja jalostus. Noudettu 8.5.2022 osoitteesta

- <https://www.raisoft.com/fi/ohjelmisto/lis%C3%A4moduulit/moduulit/NHG>
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Ball, R.L., Langlotz, C., Shpanskaya, K., Lungren, M.P., Ng, A.Y. (2017). CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. <https://doi.org/10.48550/arXiv.1711.05225>
- Rautiainen, P., Taskinen, H., Rissanen, S. (2020). Sosiaali- ja terveystalvvelujen uudistaminen - virstanpylväitä menneestä ja suuntia tulevasta. Teoksessa Hujala, A. & Taskinen, H. (toim.) *Uudistuva sosiaali- ja terveystala*. Tampere university press. (s. 15-46). <https://urn.fi/URN:ISBN:978-952-359-022-9>
- Rankin, J., Regan, S. (2004). Meeting complex needs in social care. *Housing, Care and Support*, 7(3), s. 4–8. <https://doi.org/10.1108/14608790200400016>
- Reho, T., Atkins, S., Talola, N., Sumanen, M., Viljamaa, M., Utti, J. (2018). Comparing occasional and persistent frequent attenders in occupational health primary care – a longitudinal study. *BMC Public Health* (2018) 18(1291). <https://doi.org/10.1186/s12889-018-6217-8>
- Rosengard, A., Laing, I., Ridley, J. & Hunter, R. (2007). Chapter two : Who has multiple and or/complex needs. Teoksessa *A literature review on multiple and complex needs*. Scottish Executive Social Research. Noudettu 2.5.2022 osoitteesta https://www.researchgate.net/profile/Ann-Rosengard/publication/242483070_A_Literature_Review_on_Multiple_and_Complex_Needs/links/00b7d530b6b78216af000000/A-Literature-Review-on-Multiple-and-Complex-Needs.pdf
- Ristolainen, H., Roivas, P., Mustonen, E., Hujala, A. (2020). Asiakaslähtöinen palveluohjaus. Teoksessa Hujala, A. & Taskinen, H. (toim.) *Uudistuva sosiaali- ja terveystala* (s. 241–266). <https://urn.fi/URN:ISBN:978-952-359-022-9> Uudistuva sosiaali- ja terveystala. Tampere University Press. <https://urn.fi/URN:ISBN:978-952-359-022-9>
- Sajavaara, P., (2018). Tieteellisten kirjoitelmien rakenne. Teoksessa Hirsjärvi, S., Remes, P. & Sajavaara, P. *Tutki ja kirjoita* (s249–289). Kustannusosakeyhtiö Tammi.
- Salminen, A. (2011). Kirjallisuuskatsauksen tyypit. Teoksessa *Mikä kirjallisuuskatsaus?*

- Johdatus kirjallisuuskatsauksen tyyppeihin ja hallintotieteellisiin sovelluksiin (s. 6–15). Vaasan yliopiston julkaisuja. Noudettu 23.5.2022 osoitteesta https://www.uwasa.fi/materiaali/pdf/isbn_978-952-476-349-3.pdf
- Saranto, K., Kinnunen, U.M., Jylhä, V. & Kivekäs, E. (2020). Digitalisaatio ja sähköiset palvelut uudistuvassa sosiaali- ja terveydenhuollossa. Teoksessa Hujala A., & Taskinen, H. (toim). *Uudistuva sosiaali- ja terveysala* (s. 179–214). Tampere University Press.
- Sosiaalihuoltolaki. (1301/2014). <https://finlex.fi/fi/laki/ajantasa/2014/20141301>
- Sinkkonen, S., Taskinen, H., Rissanen, S. (2018). Sosiaali- ja terveystalouden integrointi ja johtaminen. Teoksessa Rissanen, S. & Lammintakanen, J. *Sosiaali- ja terveystalouden johtaminen* (s. 105–128). Sanoma Pro Oy.
- Sintonen, H. & Pekurinen, M. (2006). Keskeiset käsitteet ja terveystalouden osa-alueet. Teoksessa Sintonen, H. & Pekurinen, M. *Terveystaloustiede* (s. 27–60). WSOY.
- Stenvall, J. & Virtanen, P. (2021). Systemisen muutoksen reformikomponentit. Teoksessa *Ihmiskeskeinen hallinnon uudistaminen* (s. 110–136). Tietosanoma Oy.
- *Stewart, S.L., Poss, J.W., Thornley, E. & Hirdes, J.P. (2019). Resource Intensity for Children and Youth: The Development of an Algorithm to Identify High Service Users in Children’s Mental Health. *Health Services Insights*, 12, s. 1–11. <https://doi.org/10.1177/1178632919827930>
- Strang, K. & Sun, Z. (2020). Hidden big data analytics issues in the healthcare industry. *Health Informatics Journal*. Vol (26), s. 981-998.
- Terveydenhuoltolaki. (1326/2000). <https://finlex.fi/fi/laki/ajantasa/2010/20101326>
- Terveyden ja hyvinvoinnin laitos. (2022a). Monialaisen palvelutarpeen ennakointi tekoälyn avulla - kansallinen kehittämisspilotti ikäihmisten asiakasryhmää koskien. Noudettu 1.5.2022 osoitteesta <https://innokyla.fi/fi/kokonaisuus/monialaisen-palvelutarpeen-ennakointi-tekoalyn-avulla-kansallinen-kehittamispilotti>
- Terveyden ja hyvinvoinnin laitos. (2022b). Tietoa RAI-järjestelmästä. Ikääntyminen. Noudettu 8.5.2022 osoitteesta <https://thl.fi/fi/web/ikaantyminen/palvelutarpeiden-arviointi-rai-jarjestelmalla/tietoa-rai-jarjestelmasta>
- Terveyden ja hyvinvoinnin laitos. (2021c). Uusi algoritmi arvioi riskiä sairastua

sydäninfarktiin tai vakavaan aivoverenkiertohäiriöön – THL mukana tutkimuksessa. Noudettu 17.8.2022 osoitteesta <https://thl.fi/fi/-/uusi-algoritmi-arvioi-riskia-sairastua-sydäninfarktiin-tai-vakavaan-aivoverenkiertohairioon-thl-mukana-tutkimuksessa>

- Tesler, L. (1970). *Tesler's Theorem*. Sitaatti. Noudettu 31.8.2022 osoitteesta https://www.nomodes.com/Larry_Tesler_Consulting/Adages_and_Coinages.html
- Tonelli, M., Wiebe, N., Fortin, M., Guthrie, B., Hemmelgarn B.R, James, M.T, Klarenbach, S.W, Lewanczuk, R., Manns, B.J, Ronksley, P., Sargious, P., Straus, S. & Quan, H. (2015). Methods for identifying 30 chronic conditions: application to administrative data. *BMC Medical Informatics and Decision Making*, 15(31). <https://doi.org/10.1186/s12911-015-0155-5>
- Tuomi, J. & Sarajärvi, A. (2018). Laadullisen aineiston analyysi: sisällönanalyysi. Teoksessa *Laadullinen tutkimus ja sisällönanalyysi*. (s.103–146). Tammi.
- Tuulaniemi, J. (2011). Asiakasymmärrys. Teoksessa Tuulaniemi, J. *Palvelumuotoilu* (s. 142–174). Alma Talent verkkokirjahylly.
- Valtioneuvosto. (2019). Hallitusohjelma. <http://urn.fi/URN:ISBN:978-952-287-808-3>
- Valtioneuvosto. (2022). Sote-uudistus. Uudistus lyhyesti. Noudettu 7.5.2022 osoitteesta <https://soteuudistus.fi/uudistus-lyhyesti->
- Valtiontalouden tarkastusvirasto. (2017). Paljon palveluja tarvitsevat ja käyttävät asiakkaat perusterveydenhuollossa. Noudettu 1.5.2022 osoitteesta <https://www.vtv.fi/app/uploads/2021/11/VTV-Jalkiseuranta-Paljon-palveluja-tarvitsevat-ja-kayttavat-asiakkaat-perusterveydenhuollossa-11-2017.pdf>
- Van der Heidea, I., Snoeijs, S., Quattrini, S., Struckmann, V., Hujala, A., Schellevis, F., Rijkena, M. (2017). Patient-centeredness of integrated care programs for people with multimorbidity. Results from the European ICARE4EU project. *Health Policy* (122), s. 36–43. <https://doi.org/10.1016/j.healthpol.2017.10.005>
- Virokannas, E. (2017). Eriarvoisuuden kokemuksia ja hallinnan suhteita hyvinvointipalvelujärjestelmässä. Huumeita käyttävien naisten” standpoint”. *Yhteiskuntapolitiikka*, 82(3), s. 274-283. Noudettu 23.5.2022 osoitteesta

https://www.julkari.fi/bitstream/handle/10024/135394/YP1703_Virokannas.pdf?sequence=1&isAllowed=y

- Watson, Lynn, Tarpey, M., Alexander, K., & Humphrey, C. (2003). Services for marginal and high risk groups. Teoksessa Watson, Lynn, Tarpey, M., Alexander, K., & Humphrey, C. *Supporting People: Real change?* (s. 10–18). York Publishing Services.
- *Wu, L.T., Ghitza, U.E, Spratt, S., Swartz M & Manelli, P. (2018). Substance use disorders and medical comorbidities among high-need, high-risk patients with diabetes. *Drug and Alcohol Dependence*, 186, s. 86-93. <https://doi.org/10.1016/j.drugalcdep.2018.01.008>
- Yle. (2018). "Voi hyvänen aika", huudahtaa virkamies – Tekoäly löysi 280 tekijää, jotka ennakoivat lastensuojelun asiakkuutta. 25.9.2018. Noudettu 1.5.2022 osoitteesta <https://yle.fi/uutiset/3-10413353>
- Yli-Katajisto, K. (2019). Paljon palveluita tarvitsevien asiakkaiden yksilöity sosiaali- ja terveystalvelujen yhteen kokoaminen. Akateeminen väitöskirja. Oulun yliopisto. Noudettu 7.5.2022 osoitteesta <http://jultika.oulu.fi/files/isbn9789526224084.pdf>
- Yang, S., Kwan, Y.H., Tan, S., Thumboo, J. & Low, L.L. (2018). A systematic review of the clinical application of data-driven population segmentation analysis. *BMC Medical Research Methodology*, 18(121), s. 2–12. <https://doi.org/10.1186/s12874-018-0584-9>
- Zhang, H., Meng, D., Cai, S., Guo, H., Chen, P., Zheng, Z., Zhu, J., Zhao, Q., Wang, H., Zhao, S., Yu, J. & He, Y. (2021). *Translational Cancer Research*, 10(5). Noudettu 28.2.2022 osoitteesta <https://tcr.amegroups.com/article/view/51989/html>
- Zhou, Y.Y, Wong, W & Hui, L. (2014). Improving Care for Older Adults: A Model to Segment the Senior Population. *The Permanente Journal* 18(3), s. 18-21. <http://dx.doi.org/10.7812/TPP/14-005>

Liitteet

Liite 1. Hakupäiväkirja

Päivämäärä	Tietokanta	Hakusanat	Rajaus	Osumat/ valittu (hyväksytyt)	Hyväksytyt artikkelit	Huomiot
4.6.2022	EBSCO	algorithm and complex health needs or complex health care needs.	Ei rajattu	32/4 (3)	Cohen ym. (2014), Dorr ym (2021), Lind ym (2020).	
4.6.2022	Google Scholar	algorithm and complex health needs or complex health care needs.	Ei rajattu	1,37 milj., silmäilty otsikoiden mukaan 80/6 (1).	Stewart ym. (2015)	
		Aineiston analyysi &	hakukriteerien	täsmennys		
16.7.2022	EBSCO	health service needs AND algorithms AND prediction model	2014-2023 Full text articles, english, peer review.	14 /4 (1)	Hammond ym (2018)	
16.7.2022	ScienceDirect	"health service needs" AND algorithms AND prediction model	2014-2023, Full text articles, english, peer review	7/1 (1)	Mohanty ym (2021)	" -merkillä rajattu ilmaisuuden tarkkuus, ilman tätä tuloksia yli 10 000
23.7.2022	Science Direct	"chronic health" service needs AND algorithms AND prediction model	2014-2023, Full text articles, english, peer review	191/5 (1)	Abd-Elrazek ym (2021)	" -merkillä rajattu ilmaisuuden tarkkuus, ilman tätä tuloksia yli 3000. Viiden valitun joukossa oli 1 tupla (Mohanty ym 2021)
23.7.2022	EBSCO	chronic health service needs AND algorithms AND prediction model	2014-2023, Full text articles, english, peer review	16/5 (0)	-	Lähiluvussa ei katsaukseen hyväksytyjä.
24.7.2022	ScienceDirect	"chronic conditions" AND "predictive analytics" AND "social" services AND "identify" AND profile AND "algorithm"	2014-2023, Full text articles, english, peer review	21/4 (1)	Malgieri ym (2020)	" -merkillä rajattu ilmaisuuden tarkkuus, ilman sitä hakutuloksia tuhansia
24.7.2022	EBSCO	chronic conditions AND predictive analytics AND social services AND identify OR profile AND algorithm AND discover	2014-2023, Full text articles, english, peer review	37 /1 (0)	-	Lähiluvussa ei hyväksytyjä. Haettu ensin vastaavin sanoin kuin ScienceDirect (yllä), mutta ei tuloksia -> lisätty <i>discover</i>
24.7.2022	Google Scholar	chronic health service needs AND algorithms AND prediction model	ks. yllä.	95 300, 80/8 (1).	Chouldechova ym (2018)	

Liite 2. Kuvailevan kirjallisuuskatsauksen tutkimusaineisto

Tekijä(t), vuosi, nimi ja tyyppi	Julkaisu	Tiivistelmä
Abd-Elrazek, M.A., Eltahawi, A.A, Abd- Elaziz, M.H. & Abd-Elwhab, M.,N (2021). Predicting length of stay in hospitals intensive care unit using general admission features. Vertaisarvioitu tutkimusartikkeli.	Ain Shams Engineering Journal. https://doi.org/10.1016/j.asej.2021.02.018	Koneoppimisen avulla ennakoitiin potilaan sairaalassaolon kestoa, diagnooseja tai ikää rajaamatta. Koneoppimismalleja koulutettiin oikeaan potilasdatan perusteella, Kaikki koneoppimismallit eivät kuitenkaan olleet soveltuvia, vastaavasti osan tarkkuus oli 90-92%. Kehittämistä tulee jatkaa edelleen.
Cohen C.J.,Flaks-Manov, N., ,Low, M., Balicer, R.D & Shadmi, E. (2014). High-Risk Case Identification for Use in Comprehensive Complex Care Managent. Vertaisarvioitu tutkimusartikkeli.	Population Health Management. https://doi.org/10.1089/pop.2014.0011	Tutkimuksessa tunnistettiin potilaat, joilla on riski kalliille palvelujen käytölle. Algoritmit tunnistivat heidät, joilla oli kohonnut riski kalliiden palvelujen tarpeelle, jonka jälkeen lääkärit arvioivat heidän soveltuvuuttaan interventioon. Tutkimuksen mukaan lähestymistapa on toimiva monisairaiden potilaiden tunnistamisessa ja hoitoon ohjauksessa.
Chouldechova, A., Putnam-Hornstein, E., Benavides-Prado, D., Fialko, O. & Vaithianathan, R. (2018). A case study of algorithm-assisted decision making in child maltreatment hotline screening decisions.Tutkimusartikkeli/konferenssipaperi ei vertaisarvioitu.	Proceedings of Machine Learning Research https://proceedings.mlr.press/v81/chouldechova18a.html	Tapaustutkimus lastensuojelussa tapahtuvasta palveluntarpeen tunnistamisesta. Tutkimuksessa kehitettiin algoritmi, joka voi auttaa tunnistamaan potentiaaliset lastensuojeluasiakkuudet, seulomalla asiakasrekistereitä. Tulokset esittelivät hyötyjä & haittoja.
Dorr, D.A., Ross, R.L, Cohen, D., Kansagara, D., Ramsey, K., Sachdeva, B. & Weiner, J.P. (2021). Primary care practices’ ability to predict future risk of expenditures and hospitalization using risk stratification and segmentation. Vertaisarvioitu tutkimus.artik.	BMC Medical Informatics and Decision Making. https://doi.org/10.1186/s12911-021-01455-4	Tutkimuksessa vertailtiin eri tapoja, joiden avulla lääkärit voivat ennakoida potilaan hoidon tarvetta ja kustannuksia. Algoritmit ennakoivat asiakkaan hoidon tarpeita ja kustannuksia paremmin kuin asiantuntijan intuitio. Tämä vahvisti näkemystä algoritmien hyödyistä kalliiden potilaiden hoidon ennakoinnissa.

<p>Gianfrancesco, M., Tamang, S., Yazdany, J. & Shmajuk, G. (2018). Potential Biases in Machine Learning Algorithms Using Electronic Health Record Data. Vertaisarvioitu tutkimusartikkeli, ennakkoverkkojulkaisu.</p>	<p>JAMA Intern Med. doi:10.1001/jamainternmed.2018.3763</p> <p>Valittu katsaukseen käsihaussa.</p>	<p>Artikkeli toi esiin haittoja, jotka liittyvät sähköisiä potilastietoja hyödyntäviin koneoppimisalgoritmeihin. Esimerkiksi useita diagnooseja omaavia potilaita voi olla vaikea tunnistaa algoritmien avulla.</p>
<p>Goodman, J.M., Lamson, A.L., Hylock, R.H. & Jensen, J.F (2021). Emergency Department Frequent User Subgroups: Development of an Empirical, Theory-Grounded Definition Using Population Health Data and Machine Learning. Vertaisarvioitu tutkimusartikkeli.</p>	<p>Families, Systems, & Health. http://dx.doi.org/10.1037/fsh0000540</p> <p>Valittu katsaukseen käsihaussa.</p>	<p>Koneoppimisalgoritmit luokittelivat palveluntarvetta käytön määrän vs. ominaisuuksien perustella. Algoritmit osoittivat, että määrään perustuva luokittelu ei auta tunnistamaan ensihoidossa toistuvaa palvelunkäyttöä, vaan tarkastelua tulee tehdä biopsykososiaalisesti.</p>
<p>Hammond, R., Athanasiadou, R., Curado, S., Aphinyanaphongs, Y., Abrams, C., Messito, M.J., Gross, R., Katzow, M., Jay, M., Razavian, N. & Elbel, B. (2019). Predicting childhood obesity using electronic health records and publicly available data. Vertaisarvioitu tutkimusartikkeli.</p>	<p>PLOS ONE. https://doi.org/10.1371/journal.pone.0215571</p>	<p>Tutkimuksessa algoritmit ennakoivat lapsen alttiutta ylipainoon ensimmäisistä elinvuosista saatavan tiedon perusteella. Algoritmit olivat lähes yhtä tarkkoja kuin muut ennakointimenetelmät.</p>
<p>Lind, K.E., Raban. M.Z., Brett, L., Jorgensen, M., Georgious, A., Westbrook, J.I. (2020). Measuring the prevalence of 60 health conditions in older Australians in residential aged care with electronic health records: a retrospective dynamic cohort study. Vertaisarvioitu tutkimusartikkeli.</p>	<p>Population Health Metrics. https://doi.org/10.1186/s12963-020-00234-z</p>	<p>Tutkimus tarkasteli sairauksien ilmentymistä ikäihmisten laitoshuoltoyksiköissä. Algoritmit poimivat tietoja sähköisistä potilastietokannoista. Tämän perusteella ikäihmiset luokiteltiin ryhmiin mm. terveydentilan mukaan. Kyseessä oli uusi tapa kuvata laitoshoidossa olevien ikäihmisten monialaista palveluntarvetta.</p>

<p>Malgieri, G. & Niklas, J. (2020) Vulnerable data subjects. Vertaisarvioitu tutkimusartikkeli.</p>	<p>Computer Law & Security Review. https://doi.org/10.1016/j.clsr.2020.105415</p>	<p>Tutkimuksessa luotiin viitekehys haavoittuvassa asemassa olevien henkilötietojen käytölle, ml. algoritmiperusteinen profilointi. Tutkimuksen mukaan haavoittuvassa asemassa olevat ovat haavoittuvaisia myös datan näkökulmasta.</p>
<p>Mohanty, S.D., Lekan, D., McCoy T.P., Jenkins, M. & Manda, P. (2021). Machine learning for predicting readmission risk among the frail: Explainable AI for healthcare. Vertaisarvioitu tutkimusartikkeli.</p>	<p>Patterns. https://doi.org/10.1016/j.patter.2021.100395</p>	<p>Tutkimuksessa ennakoitiin algoritmien avulla potilaan riskiä joutua takaisin sairaalahoitoon. Koneoppimisalgoritmien mukaan mm. terveystietojen käyttö ennakoiki riskiä joutua takaisin sairaalahoitoon.</p>
<p>Stewart, S.L., Poss, J.W., Thornley, E. & Hirdes, J.P. (2019). Resource Intensity for Children and Youth: The Development of an Algorithm to Identify High Service Users in Children's Mental Health. Vertaisarvioitu tutkimusartikkeli.</p>	<p>Health Services Insights https://doi.org/10.1177/1178632919827930</p>	<p>Tutkimuksessa kehitettiin algoritmi ennakoimaan lapsen ja nuoren mielenterveyspalvelujen tarvetta. Algoritmin onnistui tunnistamaan aikaisemminkin todettuja riskitekijöitä. Tuloksia voidaan hyödyntää resurssien kohdentamisessa.</p>
<p>Wu, L.T., Ghitza. U.E, Spratt, S., Swartz M & Manelli, P. (2018). Substance use disorders and medical comorbidities among high-need, high-risk patients with diabetes. Tutkimusartikkeli, ei-vertaisarvioitu.</p>	<p>Drug and Alcohol Dependence. https://doi.org/10.1016/j.drugalcdep.2018.01.008</p> <p>Valittu katsaukseen käsihaussa.</p>	<p>Tutkimuksessa selvitettiin päihde- ja mielenterveysongelmien yhteyttä kalliiseen ja monialaiseen palveluntarpeeseen. Tutkimuksessa tunnistettiin diabetes kalliiksi ja monialaista palveluntarvetta edellyttäväksi sairaudeksi. Ensin algoritmit ohjelmoitiin tunnistamaan sähköisistä potilastietokannoista korkean riskin diabeetikot. Tämän jälkeen algoritmit ohjelmoitiin tunnistamaan näiden henkilöiden päihteiden käyttöä ja mielenterveyspalvelujen tarvetta. Tämän katsottiin parantavan palveluntarpeen tunnistamista ja ennakoimista, mutta mallin soveltamiseen käytännössä sosiaali- ja terveyspalveluissa tarvitaan edelleen lisätutkimuksia.</p>