Tekoälyn hyödyntäminen mielenterveyden seurannassa ja hoidon apuna

Turun yliopisto
Tietotekniikan laitos
LuK-tutkielma
Tietojenkäsittelytiede
Kesäkuu 2025
Oliver Nielikäinen

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck -järjestelmällä.

TURUN YLIOPISTO
Tietotekniikan laitos

Oliver Nielikäinen: Tekoälyn hyödyntäminen mielenterveyden seurannassa ja hoidon apuna

LuK-tutkielma, 26 s.
Tietojenkäsittelytiede
Kesäkuu 2025

Tekoälyn rooli terveydenhuollossa on kasvanut merkittävästi viime vuosina, ja sen soveltaminen mielenterveyden seurannassa ja hoidossa tuo uusia mahdollisuuksia lisääntyviin mielenterveyshaasteisiin tarjoamalla yksilöllisempää, nopeampaa ja ennakoivampaa hoitoa. Tämä tutkielma tarkastelee tekoälyn hyödyntämismahdollisuuksia mielenterveyspalveluissa keskittyen erityisesti sen käyttöön diagnosoinnin ja hoitoratkaisujen tukena. Lisäksi tutkielmassa tarkastellaan, minkälaisia datalähteitä tekoäly hyödyntää mielenterveyspalveluissa. Käsitellään myös tekoälyn käytön eettisiä haasteita, kuten yksityisyydensuojaa, päätöksenteon läpinäkyvyyttä ja teknologian luotettavuutta. Tulokset osoittavat, että tekoäly hyödyntää monenlaisia datalähteitä, kuten puettavia laitteita, neurokuvantamista ja chatbotteja. Tekoäly voi tukea mielenterveyspalveluita sekä diagnosoinnissa että hoidossa, mutta sen tehokas ja eettinen käyttöönotto kuitenkin vaatii tarkkaa sääntelyä, moniammatillista yhteistyötä sekä potilaskeskeistä lähestymistapaa.

Asiasanat: mielenterveys, tekoäly, koneoppiminen, syväoppiminen, diagnosointi

Sisällys

1 Johdanto **1**

2 Mielenterveys ja tekoäly **4**

2.1 Mielenterveys ja mielentilan seuranta 4

2.2 Tekoäly 5

2.2.1 Koneoppiminen 6

2.2.2 Syväoppiminen 8

2.3 Tekoäly mielenterveydessä 10

3 Tekoälyn tuomat mahdollisuudet mielenterveydessä **12**

3.1 Mielenterveysdatan kerääminen 13

3.1.1 Psyykkinen 13

3.1.2 Fyysinen 14

3.2 Tekoälysovellukset diagnosoinnissa 17

3.3 Tekoälyn apu diagnoosin jälkeen 21

4 Pohdinta **23**

5 Yhteenveto **25**

Lähdeluettelo **27**

Kuvat

1.1 Tiedonhakuprosessi 2

2.1 Tekoälyn, koneoppimisen, syväoppimisen ja neuroverkkojen väliset suhteet. 9

1 Johdanto

Yhteiskunnassa lisääntyvät mielenterveydenhaasteet vaativat perinteisten hoitotapojen lisäksi uudenlaisia ratkaisuja. Samaan aikaan nopeasti kehittyvä teknologia ja etenkin tekoälyn yleistyminen herättävät ideoita ja tuovat mahdollisia ratkaisuja mielenterveyshaasteisiin. Tekoäly muuttaa mielenterveyden hoitopiiriä ja tekoälytyökalut ovat kasvavasti niin potilaiden kuin ammattilaistenkin saatavilla [1]. Tekoäly pystyy auttamaan ammattilaisia tehostaen diagnosointia ja tekemään entistä paremmin personoituja hoitosuunnitelmia sekä vähentämään avun hakemiseen liittyvää stigmaa.

Erityisen vaikeaa mielenterveysongelmien tunnistamisesta tekee niiden henkilökohtaisuus. Kaikki sairaudet tai poikkeamat ovat jokaiselle henkilökohtaisia, ja oireita tai syitä on vaikea yleistää kaikille. Tähän tutkijat toivovat saavansa paljon apua tekoälytyökaluista. Lisäksi aiheeseen liittyy paljon pohdintaa eettisestä näkökulmasta sekä ihmisten suhtautumisesta tekoälytyökaluja kohtaan.

Tässä tutkimuksessa tarkastellaan sekä nykyisiä että mahdollisia tulevia tekoälytyökaluja mielenterveyspalveluissa. Tutkitaan kuinka tekoäly pystyy auttamaan mielenterveysongelmien sekä poikkeamien tunnistamisessa ja miten se voi auttaa tarjoamaan parempaa hoitoa potilaille. Kirjallisuuskatsaus pyrkii saamaan kuvan tämänhetkisestä teknologiakehityksestä mielenterveyden parissa. Tutkimuskysymykset, joihin tullaan vastaamaan, ovat seuraavat:

- TK1: Millaisia psyykkisiä ja fyysisiä datalähteitä tekoäly voi hyödyntää mielenterveyden tilan arvioinnissa?
- TK2: Miten tekoälyä voidaan hyödyntää mielenterveyden häiriöiden diagnosoinnissa ja hoidon tukena?

Näiden lisäksi tullaan pohtimaan aiheeseen liittyviä huolenaiheita ja keskustelua, joiden yleisimpänä aiheena on käytettävä data, sovellusten toimintaperiaatteet sekä eettiset kysymykset. Tutkimuskysymyksiin vastataan kirjallisuuskatsauksena aineistosta, joka on saatu suorittamalla seuraavaa prosessia hyödyntäen:

Hakuprosessin alussa tavoitteena oli löytää sopivat tietokannat. Tietokannoiksi valikoituivat IEEE, Volter sekä PubMed, sillä niiden tulokset vastasivat parhaiten hakulauseella tavoiteltua aineistoa. Haussa käytetty hakulause oli (*"AI"* OR *"Artificial Intelligence"*) AND (*"depression"* OR *"mental health"*). Hakutulokset suodatettiin maksimissaan viisi vuotta vanhoihin sekä avoimesti saatavilla oleviin. Tiedonhakuprosessi näytetty kuvassa 1.1.

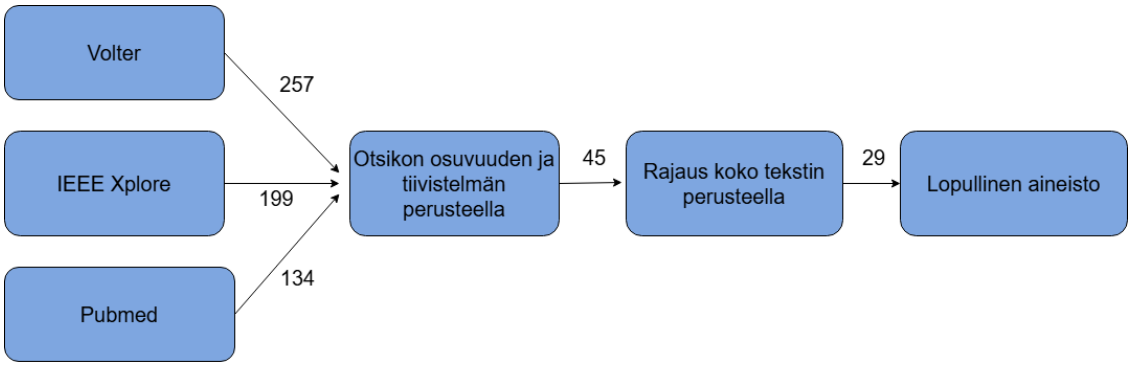

Kuva 1.1: Tiedonhakuprosessi

Seuraavassa vaiheessa löydettyä aineistoa tarkasteltiin ja rajattiin otsikon osuvuuden sekä tiivistelmän perustella. Näistä jäljelle jäi 45 potentiaalista aineistoa. Jäljelle jääneistä rajattiin vielä koko tekstin ja lähteiden luotettavuuden perusteella tutkimukseen sopiva aineisto. Tarvittua lisäaineistoa on löydetty vielä rajatun aineiston viitteistä. Lopullinen aineisto sisältää 29 artikkelia.

Tutkimus muodostuu neljästä osasta. Toisessa luvusssa taustoitetaan aihetta ja tarkemmin mielenterveyttä ja tekoälyä. Kolmas luku on käsittelyluku, jossa käydään läpi tekoälyn hyödyntämiä datankeruumenetelmiä, löydettyjä näyttöjä tekoälyn kyvyistä diagnosoinnista sekä sen tuomista mahdollisuuksista hoidon apuna. Neljännessä luvussa tarkasellaan aiheen kannalta tärkeitä huomionaiheita eli mitä tekoälytyökalujen yleistyessä ja kehittyessä tulisi huomioida. Viimeisenä lukuna yhteenvedossa käydään läpi löydettyjä tuloksia, vertaillaan niitä sekä vastataan tutkimuskysymyksiin.

2 Mielenterveys ja tekoäly

Tässä luvussa käsitellään mielenterveyttä sekä siihen liittyviä ongelmia ja niiden tunnistamistapoja. Tarkastellaan myös tekoälyn määritelmää, sen tärkeimpiä osa-alueita ja algoritmeja, joita tutkielmassa tulee ilmi, sekä tarkasteltavien tekoälyn osa-alueiden käyttömahdollisuuksia mielenterveyden parissa.

2.1 Mielenterveys ja mielentilan seuranta

Mielenterveys on ihmisen hyvinvoinnin kannalta tärkeä voimavara ja osa kokonaisvaltaista terveyttä. Terve mieli mahdollistaa sen, että ihminen pystyy tunnistamaan omia kykyjään, pitämään huolta itsestään sekä muista, selviytymään työstä ja muista elämän haasteista sekä huomioimaan yhteisönsä ja osallistumaan sen toimintaan. Heikentynyt mielenterveys vaikeuttaa näitä asioita, ja ne tuntuvat entistä vaikeammilta. [2]

Mielenterveys voidaan jakaa kolmeen osaan: sosiaaliseen, psyykkiseen ja fyysiseen. Näitä kolmea seuraamalla voidaan arvioida ihmisen mielentilaa. Mielenterveyden kannalta positiivisia asioita on tärkeä tutkia, mutta merkittävämpää on tutkia negatiivisesti vaikuttavia tekijöitä, koska niistä aiheutuu niin yksilöllisiä kuin yhteiskunnallisiakin ongelmia. Mielenterveyden yksi määritelmä onkin mielenterveyden häiriöiden puuttuminen. [2] Sosiaalista, psyykkistä ja fyysistä mielenterveyttä voidaan ja joudutaan mittaamaan eri tavoilla, jotta pystytään seuraamaan mieltä ulkopuolelta.

Yleisin mielenterveyden häiriö on masennus. Masennuksella tarkoitetaan pitkäkestoista mielenterveyden häiriötä, jolle ominaisia piirteitä ovat alakuloisuus, mielenkiinnottomuus ja vähäinen mielihyvä sekä muut kognitiiviset ja fyysiset oireet. Masennukseen johtavat syyt voivat olla myös sen seurauksia. Masennuksen mahdollisia oireita ovat masentunut mieliala, anhedonia eli kyvyttömyys tuntea mielihyvää asioista, joista sitä yleensä saa, syyllisyyden tai merkityksettömyyden tunne, itsetuhoiset ajatukset, uupumus tai energian puute, painon ja ruokahalun vaihtelut, ajattelukyvyn lasku tai päättämättömyyden tunne sekä psykomotorinen hidastuminen tai levottomuus. [3] Jos viisi näistä oireita toistuu kahden viikon ajan, voidaan puhua masennushäiriöstä. Masennusta voivat aiheuttaa myös hermosolujen muodostumista edistävien toimenpiteiden laiminlyönti ja siitä seuraava hermoston kehityksen hidastuminen. Tällaisia asioita ovat esimerkiksi huono uni ja ruokavalio, liiallinen älylaitteiden käyttö ja keinovalo, liikalihavuus ja vähäinen aivoja haastavien tehtävien tekeminen [4]. Läpikäydyt masennuksen syyt ja oireet eivät koske vain masennusta, vaan niitä voidaan soveltaa yleisesti mielenterveyden seurannassa. Näitä syitä ja oireita voidaan käyttää siis mittareina ja datalähteenä tekoälylle, joka auttaa lopullisissa diagnooseissa ja hoidossa, ja ovat tästä syystä tärkeitä huomioida parhaan mahdollisen lopputuloksen saavuttamiseksi.

2.2 Tekoäly

Tekoälyllä on useita määritelmiä, ja tiukimman määritelmän mukaan se tarkoittaa ihmisen älykkyyden jäljittelemistä tietokoneilla [5]. Määritelmä on muuttunut ajan kuluessa ja tekoälyn kehityksen mukana. Ennen tekoälynä pidettiin jotakin yhtä tehtävää osaavaa tietokonetta, kuten Deep Blue -shakkitietokone, joka teki läpimurron voitettuaan vuonna 1997 maailmanmestari Garry Kasparovin. Yhden tehtävän osaava kone ei kuitenkaan ole lähellä ihmisen älykkyyttä, sillä se ei tarkoita vielä, että kone osaisi oppia, päätellä, ratkaista ongelmia tai toimia autonomisesti. Tekoälylle

laajempi määritelmä voisikin olla, että se tarkoittaa järjestelmiä, jotka käyttäytyvät älykkäästi analysoimalla ympäristöään ja ryhtymällä toimiin - ainakin osittain itsenäisesti - haluttujen tavoitteiden saavuttamiseksi [5].

Tekoäly on kattotermi erilaisille lähestymistavoille ja tekniikoille kehittää laskennallisia järjestelmiä, jotka suorittavat kognitiivisia prosesseja ja tehtäviä, jotka ovat ominaisia ihmisille [6]. Tällaisia tehtäviä ovat esimerkiksi luonnollisen kielen ymmärtäminen, kaavojen ymmärtäminen, päätöksenteko, kokemuksesta oppiminen ja uusiin tilanteisiin mukautuminen. Näitä tekoäly kykenee toteuttamaan erilaisten prosessien ja algoritmien yhdistelmillä, joista muodostuvat tekoälyn eri komponentit. Algoritmilla tarkoitetaan tarkasti määriteltyä joukkoa sääntöjä tai ohjeita, jotka kuvaavat, miten jokin tehtävä suoritetaan vaiheittain. Seuraavaksi tarkastellaan tutkimuksessa ilmeneviä tekoälyn komponentteja, koneoppimista ja syväoppimista.

2.2.1 Koneoppiminen

Koneoppimisella tarkoitetaan algoritmeja, jotka mahdollistavat järjestelmän oppimisen ja kehittymisen sen käsittelemän datan perusteella. Koneoppimisen termi kattaa lukuisia tekniikoita, kuten ohjattu oppiminen, ohjaamaton oppiminen, syväoppiminen ja vahvistava oppiminen. Ohjatussa oppimisessa data on ennalta määriteltyä tietyn asian oppimista varten, jonka avulla kone oppii hahmottamaan haluttuun asiaan liittyviä yhtäläisyyksiä ja kykenee täten tunnistamaan halutun asian ympäristöstään. Sitä vastoin ohjaamaton oppiminen ei käytä määriteltyä dataa, jolloin se oppii tunnistamaan sisäisiä rakenteita datasta kohdennettujen piirteiden sijaan. [6] Erilaisiin tavoitteisiin ja tarkoituksiin käytetään eri oppimisen tekniikoita, ja niiden sovellusmahdollisuudet ovat laajat. Koneoppimisalgoritmit kykenevät analysoimaan mielenterveyspotilaiden dataa, kuten käytösmalleja tai mitattuja terveystietoja, auttaakseen erilaisten mielenterveysongelmien diagnosoinnissa. Ne voivat myös auttaa hoidon ohjaamisessa potilaan datan, historian ja vastausmallien perusteella.

Tarkastellaan seuraavaksi koneoppimisen yleisimpiä algoritmeja, joihin kuuluu niin luokittelu-, regressio- kuin myös klusterointialgoritmit. [6]

Ensimmäisenä tarkastellaan luokittelualgoritmeista päätöspuualgoritmia, joka on laajasti käytetty valvotun oppimisen algoritmi. Se soveltuu sekä luokittelu- että regressio-ongelmiin. Päätöspuumallin koulutuksessa keskeistä on juurisolmujen määrittäminen sekä sisäsolmujen jakaminen [7]. Tämän jälkeen käsiteltävä havaintoaineisto etenee puun yläosasta lehtisolmuihin ehtojen ohjaamana. Solmut sisältävät joko ehtoja etenemisestä päätöspuussa tai lopullisia tuloksia [7]. Satunnaismetsä on algoritmi, jossa yhdistetään useiden päätöspuiden (metsän) ennusteet. Kukin käytetty puu koulutetaan eri osajoukolla alkuperäisestä aineistosta, joka auttaa vähentämään ennustusvirheitä ja hallitsemaan ylisovittamista [7]. Seuraavaksi tarkastellaan tukivektorikonetta, joka etsii parhaan mahdollisen rajan eri luokkien erottamiseksi. Se käyttää vain tärkeimpiä havaintoja (tukivektoreita) tämän rajan määrittämiseen ja voi tarvittaessa taivuttaa rajaa, jotta monimutkaisemmat erot saadaan näkyviin [8]. Kaksi viimeistä käsiteltävää luokittelualgoritmia ovat naiivi bayes- sekä k-lähimpien naapurien algoritmi. Naiivi bayes -luokittelija on ohjattu koneoppimismenetelmä, joka perustuu Bayesin kaavaan. Algoritmi olettaa, että kaikki piirteet ovat ehdollisesti riippumattomia annetun luokan suhteen. Tämä yksinkertaistus mahdollistaa tehokkaan ja nopean luokittelun, vaikka piirteet olisivatkin todellisuudessa riippuvaisia [9]. Viimeinen luokittelualgoritmi, k-lähimmät naapurit, on ei-parametrinen algoritmi, joka arvioi havaintojen välistä yhteyttä ominaisuusavaruudessa tarkastelemalla lähimpien havaintojen jakaumaa [7]. Algoritmin tarkkuuteen vaikuttaa keskeisesti valittu k-arvo, joka määrittää, kuinka monta esimerkkiä otetaan huomioon päätöksenteossa.

Regressioalgoritmeista tarkastellaan kolme yleisintä eli lineaarinen-, logistinen- sekä LASSO-regressio. Lineaarinen regressio on tilastollinen menetelmä, jonka tavoitteena on löytää parhaat mahdolliset kertoimet syötemuuttujien ja vasteen väli-

selle lineaariselle yhteydelle. Tämä voidaan saavuttaa minimoimalla ennustettujen ja todellisten arvojen välinen virhe, yleisesti pienimmän neliösumman menetelmällä. [7]. Logistinen regressio taas on algoritmi, joka rakentaa tilastollisen mallin kuvaamaan binäärisen tai dikotomisen (kyllä tai ei) lopputuloksen ja riippumattomien, ennustettavien tai selitettävien, muuttujien välistä suhdetta [10]. Kolmas käsiteltävä regressiomalli eli LASSO tulee sanoista "Least Absolute Shrinkage and Selection Operator". LASSO hyödyntää lineaarista regressiota ja sen erityispiirteenä on kyky suorittaa automaattista muuttujavalintaa. Se asettaa joidenkin vähemmän tärkeiden selitettävien muuttujien kertoimet täsmälleen nollaksi ja voi poistaa ne kokonaan mallista [7]. Tämä tekee mallista yksikertaisemman ja helpommin tulkittavan.

Tarkastellaan vielä lyhyesti jäljelle jäänyt koneoppimisalgoritmi eli k-means klusterointi. K-means klusterointi on tunnettu ohjaamaton tekniikka datan klusterointiin eli ryhmittelyyn ilman ennalta määriteltyjä luokkia. se pyrkii löytämään rakenteita datasta. [11] Tavoitteena on havaintoaineiston jakaminen n datapisteeseen perustuen k klusteriin, joissa saman klusterin pisteet muistuttavat mahdollisimman paljon toisiaan ja eri klustereiden pisteet taas mahdollisimman vähän. K-means klusteroinnin ryhmittely perustuu etäisyyksien, kuten euklidisen etäisyyden, laskemiseen havaintojen ja klusterikeskusten (sentroidien) välillä. Tarkastellaan seuraavaksi syväoppimista ja siinä tarvittavia tekniikoita. [11]

2.2.2 Syväoppiminen

Syväoppimisella tarkoitetaan tekoälyteknologiaa, joka perustuu ihmisen aivojen rakennetta jäljitteleviin neuroverkkoihin. Nämä verkot muodostuvat lukuisista kerroksista, joissa olevat keinotekoiset neuronit oppivat tunnistamaan kaavamaisia rakenteita datasta. Syväoppimisen yleisimmät sovellukset ovat kaavojen tunnistamiskyvyn kautta kuvantunnistus, luonnollisen kielen käsittely ja ennustavat mallit. [6] Luonnollisen kielen käsittely käyttää syväoppimista sen tehtävissä, eli ihmiskielen

prosessoimisessa, ymmärtämisessä, tulkitsemisessa ja tuottamisessa. Tämä on hyödyksi, kun kirjoitetusta ja puhutusta kielestä analysoidaan tunnetiloja ja muutoksia, mikä auttaa mielenterveyden seurannassa esimerkiksi chatbottien käytön kautta. Kuvantunnistus taas on osa tietokonenäköä, joka mahdollistaa visuaalisen datan analysoinnin tekoälyllä. Ilmeet ja eleet kuvaavat tunnetiloja ja kertovat paljon ihmisen hyvinvoinnista. Kuvantunnistus ja tietokonenäkö pystyvät analysoimaan näitä visuaalisia eleitä ja ovat tällä tavalla - kuten kaikki edellä mainitut tekniikat - suureksi avuksi mielenterveyden hoidossa. [6]

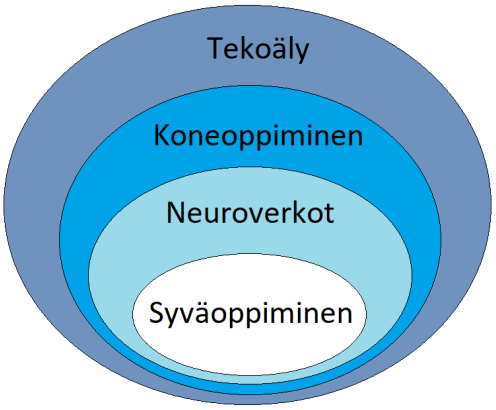

Kuva 2.1: Tekoälyn, koneoppimisen, syväoppimisen ja neuroverkkojen väliset suhteet.

Tarkasellaan neuroverkkotekniikoista kolmea asiayhteyteen tärkeää eli konvoluutioneuroverkkoja (CNN), takaisinkytkettyjä neuroverkkoja (RNN) sekä pitkän ja lyhyen aikavälin muistia (LSTM). CNN:t perustuvat ihmisen visuaaliseen aivokuoreen ja niitä käytetään esimerkiksi kuvantunnistuksessa. CNN:t koostuvat sarjasta kuvioita tunnistavista konvoluutiokerroksista sekä tietoa tiivistävistä alinäyttennottokerroksista [12]. Lopuksi seuraavat täysin kytketyt kerrokset, jotka tekevät lopullisen luokittelun. CNN:stä tehokkaan tekee se, että normaaleista neuroverkoista poiketen jokainen neuroni ei ole kytköksissä aiemman kerroksen kaikkiin neuroneihin, vaan ainoastaan sen paikalliseen alueeseen.

RNN on neuroverkko, jossa prosessointiyksiköt muodostavat syklin. Kerroksen

tulos siirtyy seuraavalle kerrokselle, ja koska verkossa on usein vain yksi kerros, tieto palaa takaisin itseensä muodostaen palautesilmukan [12]. Tämä mahdollistaa sen, että verkko muistaa aikaisemmat tilat ja käyttää sitä hyödyksi nykyisen lopputuloksen määrittämiseksi. Esimerkiksi, jos lauseessa on kolme sanaa, jokainen sana olisi oma kerros, verkko avattaisiin kolmesti, koska se rullaisi kaikkien sanojen kerrosten läpi. Sopii tämän takia hyvin puheen tai tekstin käsittelyyn tai videon analysointiin kuva kerrallaan.

LSTM on implementaatio toistuvista neuroverkoista. Se voi säilyttää tietoa aiemmista tiloista ja se voidaan kouluttaa tehtäviin, joissa tarvitaan muistia tai tilan tietoisuutta [12]. Se täyttää osittain toistuvien neuroverkkojen ongelman, eli häviävät gradientit, joka vaikeuttaa pitkien riippuvuuksien yli oppimista. LSTM koostuu muistisoluista. Niiden läpi kulkevaa tietoa ohjaavat syöte-, unohdus- ja tulosportit. Portit päättävät, mitä tietoa pitää säilyttää, unohtaa tai käyttää lopputuloksen laskennassa. LSTM:ää käytetään sarjamaisen datan käsittelyyn, jossa konteksti ja aiempi tila ovat olennaisia, kuten tekstin tai puheen analysointi. Muun muassa Apple, Google ja Amazon käyttävät tätä tekniikkaa puheentunnistussovelluksissaan. [12]

2.3 Tekoäly mielenterveydessä

Tekoäly on kiihtyvän kehityksensä ansiosta kasvattanut vaikutustaan yhteiskunnassamme suuresti ja viime vuosina sen mahdollisuudet mielenterveyden apuvälineenä ovat kasvaneet paljon. Edellisessä luvussa tarkasteltiin joitakin mahdollisia sovelluksia, mutta taustoitetaan tässä luvussa vielä paremmin tekoälyn merkitystä mielenterveydessä.

Aiemmassa alaluvussa läpikäytyjen tekniikoiden ja sovellusten avulla tekoäly luo aivan uusia mahdollisuuksia lisätä tietoisuutta sekä hoitoapua mielenterveydessä. Mainitsemisenarvoinen tekoälyn sovellus mielenterveystietoisuudessa on sosiaalisen median datan analysointi ja säätely [6]. Chatbottien ja sosiaalisen median kautta

tekoäly voi analysoida ja oppia mielenterveydestä, mutta myös säädellä sen oppiman ja tietämän mukaan siellä tulevaa sisältöä, ohjaamalla käyttäjiä tietoisuuteen mielenterveydestä ja esimerkiksi juuri sosiaalisen median käytön vaikutuksista mielenterveyteen. Etenkin tekoälypohjaiset chatbotit on suunniteltu niin, että ne voivat käydä empaattista keskustelua ihmisten kanssa antamalla henkilökohtaista apua, vähentämällä stigmaa ja ohjaamalla tarvittaessa hoitoon.

Tekoäly antaa paljon tukea mielenterveyden hoitoon täydentämällä perinteisiä menetelmiä. Se mahdollistaa esimerkiksi mobiilisovelluksissa lääkityksen muistutusten lähettämisen, sivuvaikutusten seurannan, mielialavaihteluiden analysoinnin ja yhteydenpidon hoitohenkilöön. Digitaalinen fenotyypitys hyödyntää älylaitteiden ja sosiaalisen median dataa, jotta voidaan tunnistaa käyttäytymismuutoksia, kuten äkillisen liikunnan vähenemisen, joka saattaa viitata masennukseen. Lisäksi tekoäly edistää vertaistukiryhmien muodostumista ja seuraa yksilön edistymistä, mikä auttaa ylläpitämään motivaatiota ja tukee toipumisprosessissa [1].

3 Tekoälyn tuomat mahdollisuudet mielenterveydessä

Teknologian kehitys ja sen luomat mahdollisuudet ihmisten hyvinvoinnissa, tämän tutkimuksen tapauksessa mielenterveydessä, tarjoavat uusia keinoja mielenterveysongelmien tunnistamiseen ja hoitamiseen. Tekoäly toimii vahvana edistäjänä vanhojen hoitotapojen rinnalla parantaakseen mielenterveyttä, mutta luo myös aivan uusia lähestymistapoja.

Hoitoprosessi mielenterveysongelmissa etenee oireiden ilmenemisestä ja seurannasta diagnoosin saantiin ja siitä hoitosuunnitelman rakentamiseen. Tekoäly luo mahdollisuuksia jokaisessa prosessin vaiheessa. Se on parantanut huomattavasti mielenterveysongelmien ennustamisessa ja aikaisessa tunnistamisessa, diagnoosien tarkkuudessa ja arvioinnissa, henkilökohtaisten hoitosuunnitelmien rakentamisessa sekä muussa aihealueen tutkimuksessa [13]. Käydään tässä luvussa läpi prosessin eri vaiheissa hyödynnettäviä tekoälyn sovellustyyppejä.

3.1 Mielenterveysdatan kerääminen

Mielenterveyden kaikki kolme osaa, sosiaalinen, psyykkinen ja fyysinen, on huomioitava mielenterveyden seurannassa [2]. Kaikkiin niihin liittyy piirteitä, joiden muutoksista voidaan tehdä paljon johtopäätöksiä mielen hyvinvoinnista. Sosiaalista dataa on vaikeampi kerätä sellaisenaan, mutta sitä voidaan tuottaa yhdistämällä seuraavaksi käsiteltäviä tapoja.

3.1.1 Psyykkinen

Psyykkisiä oireita, kuten masentunutta mielialaa, anhedoniaa, syyllisyyden tai merkityksettömyyden tunnetta tai jopa itsetuhoisia ajatuksia, on vaikea seurata ulkoapäin. Chatbotit ja virtuaaliset avustajat voivat olla helposti saavutettava ensivaiheen apuväline kyseisten alkuoireiden seulonnassa ja vakavuuden arvioinnissa [13]. Laajoihin kielimalleihin perustuvat chatbotit ja virtuaaliset avustajat voivat kerätä ja arvioida dataa potilaan mielenterveydestä ja antaa nopeaa hoitoapua tai ohjausta ihmishoidon pariin. Koska chatbotit eivät ole ihmisiä, voi potilaalla olla matalampi kynnys avautua enemmän voinnistaan, jolloin saadaan parempi kuva mielenterveyden tilasta. Virtuaaliavustajat voivat myös ylläpitää seurantaa kyselemällä säännöllisesti potilaan olosta esimerkiksi mobiilisovelluksen avulla. [13]

Tunteiden tunnistaminen auttaa kartoittamaan kokonaisvaltaista psyykkistä hyvinvointia. Ihmisen tunteita voidaan määritellä fysiologisista signaaleista, ilmeistä, puheesta ja fyysisistä vihjeistä, kuten asennoista ja eleistä [14]. Tätä ilmiötä kuvataan usein käsitteellä *affect*, jolla tarkoitetaan tunteellisen ja psyykkisen mielentilan tunnistamista (engl. affective, emotional, and physiological detection and recognition). Laaja määrä tekoälytekniikoita on hyödynnetty affect-tunnistamisen sovelluksissa, kuten koneoppimista, neuroverkkoja, hakualgoritmeja, laajoja kielimalleja ja kuvantunnistusta. Kuvantunnistuksen avulla voidaan tunnistaa ilmeitä ja eleitä, joita voidaan yhdistää erilaisiin tunteisiin. [14] Laajat kielimallit mahdollistavat puheen ja tekstin ymmärtämisen, joista voidaan muodostaa viittauksia eri tunnetiloihin. Puhetta ja tekstiä voidaan saada esimerkiksi puhelimen teksteistä, kuten viesteistä ja äänitallenteista. X-päivitykset (entinen Twitter) ovat olleet yleinen tiedonhakukohde tätä varten [15]. [14]

3.1.2 Fyysinen

Fyysisiä piirteitä mielenterveydestä on yksinkertaisempi seurata, mutta usein piirteet tai oireet voivat liittyä myös muihin ongelmiin kuin mielenterveydellisiin, tai niissä ei voida huomioida kaikkia ympäristöön tai tilanteeseen liittyviä asioita. Niistä kuitenkin voidaan saada paljon hyödyllistä dataa käyttöön. Fyysisiksi seurannan kohteiksi voidaan luokitella uni, painon vaihtelut, aivojen toiminta, liikunnan määrä, päivittäinen käyttäytyminen ja esimerkiksi erilaisten fyysisten mittareiden, kuten sykkeen seuranta.[2], [4]

Unen ja käyttäytymisen seurannassa yhtenä mahdollisuutena on puhelinsovellusten käyttö. Sovellukseen käyttäjä päivittää tietoja unestaan ja täyttää kyselyitä liittyen sosiodemografisista tekijöistä, älypuhelimen käytöstä ja käytösmalleista sekä hyvinvoinnista [16]. Sovellus seuraa myös puhelimen näytön aktivointeja ilmoitetun unen aikana varmistaakseen tiedon oikeellisuuden. Jos tiedoissa tulee muutoksia, sovellus lähettää lisäkysymyksiä ja kehottaa mahdollisesti korjaamaan muutokset. Kyseinen sovellus toimii hyvin seurannassa, jos käyttäjä täyttää tietoja säännöllisesti ja rehellisesti ja pystyy tulkitsemaan omaa käytöstään ja vointiaan luotettavalla tasolla. Kompastuskivenä sovelluksen käytössä on, että se vaatii käyttäjältä oma-aloitteisuutta kirjata tarvittavat tiedot säännöllisesti, joka saattaa joillekin olla haaste. [16]

Unta voidaan myös seurata puettavilla terveyslaitteilla. Laitteet kuten älykellot, -sormukset ja -rannekkeet tai muunlaiset sensorilaitteet tuottavat käyttäjilleen ajankohtaista tietoa heidän unestaan, terveydestään, liikunnastaan ja ympäristöstään. Näiden laitteiden etu seulonnassa on niiden käyttäjäystävällisyys. Ne keräävät jatkuvasti luotettavaa tietoa kehittyneillä sensoreillaan, mutta eivät vaikuta käyttäjän elämään häiritsevästi. Puettavien laitteiden integrointi tekoälyn kanssa on noussut yhdeksi merkittävimmäksi edistysaskeleeksi tekoälyssä mielenterveyden ongelmien seulonnassa, diagnosoinnissa ja hallinnassa [13]. Askeleet, syke, kehon lämpötila ja veren happipitoisuus ovat esimerkkejä seurattavista parametreistä, joiden avulla voidaan seurata terveyttä ja täten myös mielenterveyttä. Etenkin sykeen vaihteluilla ja unen sekä liikunnan vähentymisellä on todettu paljon yhteyksiä masennukseen ja ahdistukseen [13].

Viimeisimpänä tässä tutkielmassa käsiteltävistä seulontatavoista on neurokuvantaminen. Tämä tapa on läpikäydyistä tekniikoista vähiten käyttäjäystävällinen, sillä tutkiman perusteella ei ole vielä kehitetty helppokäyttöisiä ja huomaamattomia laitteita, joilla voisi omatoimisesti seurata aivojen toimintaa. Neurokuvantaminen joudutaankin toteuttamaan yleisesti kliinisissä olosuhteissa. Yleinen aivojen toimintaa seuraava menetelmä on elektroenkefalografia (EEG), jossa aivojen sähköistä aktiivisuutta ja aivoaaltojen vaihteluita mitataan pään pinnalle asetettavien elektrodien avulla, jotka toimivat kehon virtojen välittäjinä mittalaitteille. Mielentiloja seuratakseen on katsottava alfa-aaltoja (rentoutuminen), beta-aaltoja (valveillaolo), delta-aaltoja (uni) ja theta-aaltoja (rauhoittuminen). Jokaiselle aallolle on ominaista erilaiset amplitudit ja taajuudet, ja ne vastaavat eri kognitiivisia tiloja. [14] Mielentilan tunnistaminen EEG-signaalien sekä muidenkin kahdeksan aineistossa [14] läpikäydyn neurokuvantamismenetelmän avulla vaatii monialaista ymmärrystä. Psykologia, insinööri- ja neurotiede sekä tietojenkäsittelytiede mahdollistavat yhdessä paremman kokonaiskuvan hahmottamisen mielentilasta. Muut aineistossa esitetyt non-invasiiviset, eli toimenpiteet, jotka eivät vaadi leikkausta, mittaavat hyvin samoilla tavoilla erilaisia sähköisiä muutoksia aivoissa. Saatu data voi olla tarkempaa kuin muilla tutkimusmenetelmillä, mutta neurokuvantamisen vaatimat olosuhteet vaikeuttavat sen käytön yleistymistä. [14]

3.2 Tekoälysovellukset diagnosoinnissa

Yhdistämällä päälle puettavista laitteista ja kuvantamisjärjestelmistä (MRI ja EKG) saatavat tulokset kognitiivisiin järjestelmiin, voidaan saada kuva (arvio) yksilön tilasta terveydenhuollon ammattilaisille. Nykyään jo 300 sanan analyysi voi auttaa enuustamaan potilaan sairastaman psykoosin todennäköisyyttä. [17]. Näin sanottiin jo 2018 julkaistussa kirjassa *Tekoälyä hyödyntävät ratkaisut ja mahdollisuudet mielenterveyden häiriöissä*. Kirjan julkaisusta on jo kulunut kuusi vuotta, jolloin ei ollut vielä olemassa ChatGPT:tä ja muita yhtä tehokkaita tekoälyjä. Kyseinen viittaus kuvaa hyvin sitä, kuinka varhaisessa vaiheessa on jo saatu apua mielenterveysongelmien ennakoimiseen, ja mihin teknologia nykyään pystyy, kun kehitys on jatkunut eksponentiaalisena.

Jotta potilaat suostuvat hyväksymään saamansa diagnoosin tai sen, että tekoäly on ollut vaikuttamassa hänen hoitoonsa, on lääkärin ensin itse luotettava sen kykyihin ja luotettavuuteen. Vaikka tekoäly suoriutuu sille annetuista tehtävistä tavattoman hyvin, lääkärien suhtautuminen sen hyödyntämiseen voi olla edelleen varautunut, joka johtuu siitä, että ei tiedetä millaista dataa käsitellään oikeasti ja miten siitä tehdyt päätelmät on saatu aikaiseksi [18]. Artikkelin [18] läpikäydyn tutkimuksen mukaan 60% terveydenhuollon ammattilaisista luottivat tekoälyn/koneoppimisen apuun. Potilaiden luotto tekoälyyn kliinisessä käytössä oli 71%. Voidaan todeta, että erityisesti asiaa koskevien ammattilaisten keskuudessa tulee lisätä tietoisuutta siitä, miten tekoäly käsittelee tietoa, jotta saadaan kasvatettua luottamusta teknologian antamia päätelmiä kohtaan.

Tekoäly käsittelee kerättyä dataa ja pyrkii löytämään ohjatun koneoppimisen avulla mahdollisia poikkeavia piirteitä mielentilasta. Koska mielenterveyden häiriöt voivat olla useiden eri häiriöiden yhdistelmiä ja niiden oireet ovat subjektiivisia sekä vaikeasti yleistettäviä kaikille, yksittäisten piirteiden tarkastelu ei riitä sellaisenaan. Aiemmin tutkielmassa läpikäytyjen mitattavien tietojen lisäksi tulisi ottaa huomioon kulttuuritausta ja sosioekonominen asema, asenteet monimuotoisuutta kohtaan sekä konteksti [14]. Näistä ja kaikista mahdollisista ihmisen elämään vaikuttavista tekijöistä voidaan luoda selkeämpiä mielenterveyden poikkeamiin viittaavia rakenteita ohjaamattoman koneoppimisen ja syväoppimisen avulla. Tarkastellaan seuraavaksi miten ja millaisilla tekniikoilla data käsitellään.

Korrelaatioiden ja rakenteiden tunnistamiseen käytetään useita erilaisia koneoppimistekniikoita, joissa hyödynnetään erilaisia tekoälyalgoritmeja. Seuraavana listattu yleisimpiä tekniikoita ja niissä käytettäviä algoritmeja:

- Luokittelu: naiivi bayes [13]–[15], [19]–[21], päätöspuu [13]–[15], [19]–[24], satunnaismetsä [13]–[16], [18]–[21], [23], [24], tukivektorikone [13]–[15], [19]–[21], [25], k-lähimmät naapurit [13]–[15], [18]–[21], [23]
- Regressio: lineaarinen regressio [13]–[15], [19], [25], [26], LASSO regressio [14], [19], [20], logistinen regressio [13]–[16], [19]–[21], [24], [27]
- Klusterointi: k-means klusterointi [14], [20], [25]

Kyseisistä algoritmeista käsiteltiin aineistossa eniten päätöspuuta, satunnaismetsää, tukivektorikonetta, k-lähimpiä naapureita, naiivi bayesia sekä logistista regressiota.

Tutkimuksessa [19] vuodelta 2023 on käsitelty eri tutkimuksia tekoälyalgoritmien saamista F1-tuloksista masennuksen tunnistamisessa, lähinnä tekstidatasta. F1-tulos yhdistää tarkkuuden ja herkkyyden arvioidakseen mallin tasapainoista suoritusta [20], [28]. Se on erityisen hyödyllinen epätasapainoisissa aineistoissa, joissa pelkkä tarkkuus ei riitä kertomaan ennusteen luotettavuudesta ja on tästä syystä hyvä mittari käsiteltävässä aiheessa. Mittari on 0 ja 1,0 välillä, josta 1,0 tarkoittaa parasta mahdollista tarkkuutta [28]. Tutkimuksessa naiivi bayes -luokittelija-algoritmi sai F1-tulokseksi 0,82. Tutkimuksessa käytiin läpi toinen tutkimus, jossa satunnaismetsä sai tulokseksi 0,644, mutta toisessa tutkimuksessa satunnaismetsä sai tulokseksi 0,827. Tämä oli myös kyseisen tutkimuksen paras malli, kun käytettiin tunnistamisessa vain 12 piirrettä. Huomataan siis, että saman mallin käytössä ja lopputuloksissa voi eri tutkimustavoissa olla suuriakin eroja. Tukivektorikoneen käytössä oli myös suuria vaihteluita. Tulokset heittelehtivät 0,46 ja 0,91 välillä, mutta tuloksiin vaikuttaa käytetyn datan lisäksi esimerkiksi tekstinkäsittelytekniikat. Toisessa tutkimuksessa [15] tukivektorikoneella saatiin tunnistettua masennus Twitter-viesteistä F1-tuloksella 0,7973. Vielä parempaan tulokseen päädyttiin, kun käytettiin 30 piirteen tukivektorikonetta, 0,93. [19]

Koneoppimisalgoritmien tulokset antavat lupaavia merkkejä tarkkuuden suhteen, mutta heittoja vielä huonoihin tuloksiin löytyy huomattavasti. Tulokset riippuvat pitkälti täysin algoritmien käyttämästä datasta, joka voi tutkimuksissa vaihdella huomattavasti. Tulosten perusteella isoin varianssi nähtiin tukivektorikoneessa, joka voi tarkoittaa sen olevan erittäin altis datan vaihtelulle. Satunnaismetsällä saatiin pienempi varianssi, mutta lopulliset tulokset eivät ole vielä riittävällä tasolla yleiseen käyttöön.

Tarkastellut koneoppimisalgoritmit eivät vielä olleet täysin vakuuttavia. Näitä tehokkaampana on kehitetty samassa tutkimuksessa käsitelty syväoppimismalli, joka tunnistaa masentuneet ja stressaantuneet käyttäjät. Tämä syväoppimismalli käyttää CNN- ja RNN-verkkoja sekä BiLSTM-arkkitehtuuria. BiLSTM on muuten samanlainen kuin LSTM, mutta siinä voidaan edetä syötteessä myös taaksepäin. Mallin F1-tulos oli 0,92 masentuneiden käyttäjien tunnistamisessa, mikä on selkeästi tarkempi kuin koneoppimisalgoritmit satunnaismetsä ja naiivi bayes [19]. Muut tutkimuksessa läpikäydyt tutkimukset käyttivät enimmäkseen myös CNN- ja RNN-verkkoja, mutta lisäksi hyödynnettiin LSTM:ää. LSTM:n F1-tulokset tutkimuksessa vaihtelivat 0,77:n ja 0,99:n välillä. CNN-verkon tulokset vaihtelivat välillä 0,91 ja 0,99. Tutkimusten datana on käytetty enimmäkseen tekstidataa. Muiden neuroverkkojen tulokset olivat hieman alhaisemmat. Toisessa tutkimuksessa [15] CNN sai sMRI-kuvadatasta tunnistettua ensimmäisen jakson psykoosin ja kaksisuuntaisen mielialahäiriön jopa tuloksella F1=0,9975. SMRI:llä tarkoitetaan rakenteellista magneettikuvantamista, jolla pyritään löytämään poikkeamia rakenteista, tässä tapauksessa aivoista [15]. [19]

Kuten huomataan tuloksista, parhaimmaksi ja pienimmän varianssin omaavaksi tekniikaksi voidaan todeta CNN-verkot, ja kaikkein parhaimmaksi sovellukseksi sen ja LSTM:n yhdistelmä, joka sai jopa tuloksen 0,99. Huomataan, että syväoppimismallit ovat jo tarkkoja, ja parempia kuin koneoppimismallit, tunnistamaan mielenterveyden haasteita erilaisista datatyypeistä. Kun mietitään tuloksia, F1-tulos saadaan tarkkuudesta ja herkkyydestä, esimerkiksi tulos 0,80 voi olla tarkkuus 0,75 ja herkkyys 0,85. Tätä kyseistä tarkkuutta 0,75 voidaan jo pitää ihmistä parempana, etenkin mielenterveyshaasteiden monimutkaisuuden takia.

3.3 Tekoälyn apu diagnoosin jälkeen

Hyvien diagnosoinnissa saatujen tulosten lisäksi tekoäly antaa apua ja tehokkuutta personoitujen hoitosuunnitelmien suunnittelemisessa ja toteutuksessa. Räätälöinnissä hyödynnetään muun kerätyn datan lisäksi genetiikkaa, käyttäytymisdataa ja aiempia hoitovasteita. Esimerkiksi ARPNet-tekoälyverkko ennustaa etukäteen, miten potilas todennäköisimmin reagoi tiettyyn masennuslääkkeeseen ennen sen määrämistä. [19] Tämä mahdollisuus vähentää huomattavasti perinteistä yrityksen ja erehdyksen kautta lähestymistä [29]. Toistuva transkraniaalinen magneettistimulaatio (rTMS) on hoitomenetelmä, jonka teho voidaan ennustaa fMRI-signaalien tai EEG-datan perusteella. Tutkimuksessa [19] tunnistettiin neljä eri masennuksen alatyyppiä fMRI-datan avulla, ja kukin tyyppi reagoi eri tavalla rTMS-hoitoon. Lisäksi tekoälymalli pystyi ennustamaan hoitovasteen paremmin kuin pelkkä oirekuva. [19], [29]

Tekoäly auttaa myös videoterapiassa analysoimalla tunteita reaaliajassa (ääni, ilmeet, puhe). Tutkimuksessa [29] tuotiin ilmi Kintsugi-alusta, joka tarjoaa terapeuteille tunnepalautetta potilaan puheen ja kasvojen analyysistä, mikä auttaa mukauttamaan terapiatekniikoita ja mahdollisten poikkeavien piirteiden tunnistamisessa. [29]

Datan keräämisen ja hoidon tarpeen tunnistamisen lisäksi käsitellyt chatbotit ja virtuaaliavustajat toimivat myös hoidossa. Ne voivat tarvittaessa muistuttaa potilasta pysymään hoitosuunnitelmassa ja seurata potilaan vointia vuorovaikutteisesti [13]. Kuten virtuaaliavustajat Woebot ja Wysa tarjoavat jatkuvaa tukea käyttäjälle ja analysoivat viestinnän kautta mielialaa ja emotionaalista tilaa. Nämä voivat reagoida huomionarvoisiin merkkeihin ja ehdottaa tarvittaessa ammattilaisapua [29]. Samoin muita, etenkin puettavia laitteita, voidaan käyttää jatkuvan datan keräämiseen ja hoidon seurantaan, jotta voidaan arvioida saatua hoitoa ja sen toimivuutta. [13], [19], [29]

4 Pohdinta

Hyviä tuloksia on saatu ja yksittäisissä tapauksissa diagnosointi ja hoidovasteen ennustaminen on todettu ihmistä tarkemmaksi. Ihmiset kuitenkin haluavat tietää, kuinka lopputuloksiin päästään, mikä onkin vielä ollut tekoälymallien haasteena. Niin lääkäreitä kuin potilaita saattaa huolestuttaa tai epäilyttää järjestelmät, jonka logiikkaa tai päätöspuuta ei ymmärretä, mikä vähentää kliinikkojen halukkuutta käyttää tai luottaa tekoälyn suosituksiin [18]. On kuitenkin huomioitava, että löydetyt ja käsitellyt aineistot ovat uusimmillaan vuodelta 2024 alkupuolelta, jonka jälkeen tulleet mallit ovat jo kehittyneempiä avaamaan päätelmiään ja miten ne rakentuvat.

Jotta tekoälyä voidaan käyttää mielenterveysdiagnooseissa ja hoidon apuna, täytyy siis ihmiten luottoa kasvattaa sitä kohtaan. Mutta kun ihmiset saadaan luottamaan tekoälyn arviointeihin ja päätelmiin, uskon että se muuttaa ihmisten suhtautumista yleisesti avun hakemiseen. Jos ensimmäinen apu tulisikin luotettavalta tekoälyltä tai ihminen saisi ilmoituksen tekoälyltä mahdollisesta ongelmasta, uskon että ihmiset olisivat vastaanottavaisempia hoidolle tekoälyn puolueettomuuden vuoksi. Kunhan ihmiset voivat luottaa, että heidän tietonsa pysyvät oikeissa käsissä, on helpompaa kertoa arkaluonteisista asioista tekoälylle. Tämä vähentäisi kynnystä avun hakemiselle, joka vaikuttaa olevan suurin haaste ihmisillä.

Paljon aihetta käsittelevä kirjallisuus on käsitellyt dataan liittyvää pohdintaa. Tekoälyn tehokkuuteen vaikuttaa paljon sen koulutukseen käytetty data. Ongelmana onkin ilmennyt, että mitä dataa on hyvä käyttää, mutta myös mistä sitä saadaan. Datan keruu on kallista ja eettisesti haastavaa, koska mielenterveysdata on arkaluontoista ja stigmaa voi esiintyä. Herääkin kysymys, missä määrin ihmiset haluavat tai voivat antaa tekoälyn käsitellä henkilökohtaista mielenterveysdataansa. Halutaan siis myös tietää, mitä dataa tekoäly hyödyntää ja kuinka se on kerännyt sen. Pidän itse tärkeänä, että pystytään rajaamaan mitä dataa tekoäly tarvitsee parhaaseen mahdolliseen lopputulokseen, jotta vältytään ylimääräisen arkaluontoisen datan jakamiselta. Tällä voidaan myös säästää ympäristöä vähentämällä tekoälyn kuluttamaa energiaa.

Jos datankeruu saadaan huomaamattomaksi ja se saadaan rajoitettua sellaiseksi, että ihmiset sen hyväksyvät, voi tekoälysovellukset tarjota ihmisille tasapuolisen mahdollisuuden saada diagnoosin ja hoitoa mielenterveyden ongelmiinsa. Tällä hetkellä alan ammattilaisia on liian vähän tarpeeseen nähden, joten tätä vaadetta olisi mahdollista täyttää tekoälysovelluksilla. Paljon kuitenkin vaatii vielä, että tekoäly voisi ihmisen täysin korjata, jos se edes on mahdollista. Hyvänä aputyökaluna sitä voidaan jo pitää. Uskon, että teknologian kehitys, oikeanlaiset säännöstelyt ja sekä tietoisuuden jakaminen tekoälyn toiminnasta voivat mahdollistaa sen, että tekoäly ratkaisee vallitsevan ja kasvavan mielenterveyskriisin.

5 Yhteenveto

Lisääntynyt hoitotarve mielenterveyden palveluissa sekä mielenterveydessä ilmenevien ongelmien haastavuus luovat haasteita yhteiskuntaamme. Lisäksi teknologian, etenkin tekoälyn, kiihtyvä kehitys tuo haasteita, mutta ennen kaikkea mahdollisuuksia. Tämän tutkimuksen tarkoituksena olikin saada selville tekoälyn tuomia mahdollisuuksia ja mahdollisia haasteita mielenterveyspalveluissa.

Tk1: Tekoäly pystyy hyödyntämään monipuolista dataa mielenterveyden tilan arvioinnissa. Mielenterveydessä seurattavat tekijät voidaan jakaa selkeiten kahteen osaan, fyysisiin ja psyykkisiin tekijöihin. Psyykkistä tekijöistä saadaan dataa chatboteilta, somepäivityksistä ja käyttäytymisdatasta. Luonnollisen kielen käsittely, puheentunnistus ja kuvantunnistaminen mahdollistavat tunteiden ja mielentilan arviointiin tarvittavan datan keruun kerätystä datasta. Puhelinsovellukset, joissa vastataan itse hyvinvointiin liittyviin kysymyksiin, on yksi datalähde niin psyykkisten kuin fyysisten tekijöiden seurantaan, mutta tehoton sen vaatiman oma-aloitteisuuden takia. Muita fyysisiä datalähteitä ovat puettavat terveyslaitteet kuten älykellot, -sormukset tai -rannekkeet. Neurokuvantamisen avulla voidaan saada myös monipuolista dataa aivojen toiminnasta ja fyysisistä ominaisuuksista tekoälyn käyttöön. Näiden tietojen avulla voidaan havaita poikkeamia, jotka voivat viitata mielenterveyden häiriöihin. Fyysinen data täydentää psyykkistä dataa ja yhdessä ne mahdollistavat kokonaisvaltaisen tilan arvioinnin.

Tk2: Tekoälyä hyödynnetään mielenterveyden diagnosoinnissa erityisesti koneoppimis- ja syväoppimismallien avulla. Näitä malleja koulutetaan erilaisilla datatyypeillä tunnistamaan oireita ja ennakoimaan häiriöitä. Luokittelualgoritmeista, naiivi bayes, satunnaismetsä ja tukivektorikoneet, on saatu lupaavia tuloksia, vaikka tulokset vaihtelevat datan laadun mukaan. Syväoppimismallit, kuten CNN, LSTM ja erityisesti BiLSTM, ovat osoittautuneet erittäin tarkaksi — parhaimmillaan F1-tuloksen ollessa jopa 0,99, joka vastaa lähes täydellistä tarkkuutta. Diagnoosin jälkeen tekoälyä käytetään hoidon suunnitteluun ja seurantaan. Esimerkiksi ARPNet-verkko voi ennustaa, miten potilas reagoi tiettyyn lääkkeeseen, ja RTMS-hoidon vasteita voidaan arvioida neurokuvantamisen avulla. Chatbotit, virtuaaliavustajat ja mobiilisovellukset tarjoavat jatkuvaa tukea ja voivat reagoida potilaan viesteihin analysoimalla emotionaalisia muutoksia. Tämä mahdollistaa hoidon personoinnin sekä parempaa ennakoitavuutta ja tehokkuutta.

Voidaan todeta, että tekoälyllä on korkea potentiaali mielenterveyden arvioinnissa, kun käytetään laajoja ja monipuolisia datalähteitä ja hyödynnetään edistyneitä analyysimenetelmiä. Tutkimusten datana oli pääosin tekstidata, esimerkiksi chatboteilta tai internetistä, sekä kuvantamisdata. Ei siis löydetty tietoa puettavien laitteiden tai puhelinsovellusten toimivuudesta vielä. Etenkin syväoppiminen on kuitenkin näyttänyt, että sen tarkkuus arvioinnissa voi yltää ihmisen tarkkuuden yli, helpottaen tätä kautta selkeästi mielenterveyden ammattilaisten työtä vaikka se ei ihmistä korvaakaan. Tekoäly tuo myös uudenlaisia, lähestyttävämpiä tapoja saada tietoisuutta ja hoitoa mielenterveysongelmiin.

Lähdeluettelo

[1] M. Zhang, J. Scandiffio, S. Younus et al., "The Adoption of AI in Mental Health Care–Perspectives From Mental Health Professionals: Qualitative Descriptive Study", *JMIR Formative Research*, vol. 7, e47847, 2023, PMID: 38060307. DOI: 10.2196/47847.

[2] L. A. Manwell, S. P. Barbic, Z. Durisko, C. Lee, E. Ware ja K. McKenzie, "What is mental health? Evidence towards a new definition from a mixed methods multidisciplinary international survey", *BMJ Open*, vol. 5, nro 6, 2015. DOI: 10.1136/bmjopen-2014-007079.

[3] G. S. Mahli ja J. J. Mann, "Depression", *The Lancet*, vol. 392, nro 10161, s. 2299–2312, 2018. DOI: 10.1016/S0140-6736(18)31948-2.

[4] H. Brody, "A journey into the causes and effects of depression", *Nature*, vol. 608, nro 7924, 2022. DOI: 10.1038/d41586-022-02204-x.

[5] H. Sheihk, C. Prins ja E. Schrijvers, "Artificial Intelligence: Definition and Background", s. 15–41, 2023. DOI: 10.1007/978-3-031-21448-6_2.

[6] A. Thakkar, A. Gupta ja A. De Sousa, "Artificial intelligence in positive mental health: a narrative review", *Frontiers in Digital Health*, vol. 6, 2024. DOI: 10.3389/fdgth.2024.1280235.

[7] M. Maabreh ja G. Almasabha, "Machine Learning Regression Algorithms for Shear Strength Prediction of SFRC-DBs: Performance Evaluation and Com-

parisons", *Arabian Journal for Science and Engineering*, vol. 49, s. 4711–4727, 2023. DOI: 10.1007/s13369-023-08176-y.

[8] N. Guenther ja M. Schonlau, "Support vector machines", *Sage Journals*, vol. 16, nro 4, 2016. DOI: 10.1177/1536867X1601600.

[9] S. Ramesh, S. Gomathi, S. Sasikala ja T. Saravanan, "Automatic speech emotion detection using hybrid of gray wolf optimizer and naïve Bayes", *International Journal of Speech Technology*, s. 571–578, 2023. DOI: 10.1007/s10772-021-09870-8.

[10] A. Das, "Logistic Regression", s. 3985–3986, 2024. DOI: 10.1007/978-3-031-17299-1_1689.

[11] M. Zubair, M. Iqbal, A. Shil, M. Chowdhury, M. A. Moni ja I. H. Sarker, "An Improved K-means Clustering Algorithm Towards an Efficient Data-Driven Modeling", *Annals of Data Science*, vol. 11, s. 1525–1544, 2024. DOI: 10.1007/s40745-022-00428-2.

[12] A. Shrestha ja A. Mahmood, "Review of Deep Learning Algorithms and Architectures", *IEEE Access*, vol. 7, s. 53 040–53 065, 2019. DOI: 10.1109/ACCESS.2019.2912200.

[13] F. Zafar, L. F. Alam, R. R. Vivas et al., "The Role of Artificial Intelligence in Identifying Depression and Anxiety: A Comprehensive Literature Review", *Cureus*, 2024. DOI: 10.7759/cureus.56472.

[14] A. Kaklauskas, A. Abraham, I. Ubarte et al., "A Review of AI Cloud and Edge Sensors, Methods, and Applications for the Recognition of Emotional,

Affective and Physiological States", *Sensors*, vol. 22, nro 20, 2022. DOI: 10.3390/s22207824.

[15] N. K. Iyortsuun, S.-H. Kim, M. Jhon, H.-J. Yang ja S. Pant, "A Review of Machine Learning and Deep Learning Approaches on Mental Health Diagnosis", *Healthcare*, vol. 11, nro 3, 2023. DOI: 10.3390/healthcare11030285.

[16] T. O. Andersen, A. S. Dissing, E. R. Severinsen, A. K. Jensen, V. T. Pham ja N. H. Rod, "Predicting stress and depressive symptoms using high-resolution smartphone data and sleep behavior in Danish adults", *Sleep*, vol. 45, nro 6, zsac067, 2022. DOI: 10.1093/sleep/zsac067.

[17] P. Vähäkainu, P. Neittaanmäki ja S. Kärkkäinen, "Tekoälyä hyödyntävät ratkaisut ja mahdollisuudet mielenterveyden häiriöissä", 2018. url: https://urn.fi/URN:ISBN:978-951-39-7362-9.

[18] O. Higgins, B. L. Short, S. K. Chalup ja R. L. Wilson, "Artificial intelligence (AI) and machine learning (ML) based decision support systems in mental health: An integrative review", *International Journal of Mental Health Nursing*, vol. 32, nro 4, s. 966–978, 2023. DOI: 10.1111/inm.13114.

[19] M. Squires, X. Tao, S. Elangovan et al., "Deep learning and machine learning in psychiatry: a survey of current progress in depression detection, diagnosis and treatment", *Brain Informatics*, vol. 10, nro 1, 2023. DOI: 10.1186/s40708-023-00188-6.

[20] A. Thieme, D. Belgrave ja G. Doherty, "Machine Learning in Mental Health: A Systematic Review of the HCI Literature to Support the Development of

Effective and Implementable ML Systems", *ACM Transactions on Computer-Human Interaction*, vol. 27, nro 5, 2020. DOI: 10.1145/3398069.

[21] A. Abd-alrazaq, R. AlSaad, S. Aziz et al., "Wearable Artificial Intelligence for Anxiety and Depression: Scoping Review", *Journal of Medical Internet Research*, vol. 25, 2023. DOI: 10.2196/42672.

[22] Talayeh, J. Torous, A. M. T. Hoyos, J. A. Naslund, J.-P. Onnela ja M. Keshavan, "Smartphone-Based Tracking of Sleep in Depression, Anxiety, and Psychotic Disorders", vol. 21, nro 49, 2019. DOI: 10.1007/s11920-019-1043-y.

[23] Q. Zheng, F. Liu, S. Xu, J. Hu, H. Lu ja T. Liu, "Artificial intelligence empowering research on loneliness, depression and anxiety — Using Covid-19 as

an opportunity", *Journal of Safety Science and Resilience*, vol. 4, nro 4, s. 396–409, 2023. DOI: 10.1016/j.jnlssr.2023.10.002.

[24] Z. Tian ja D. Yi, "Application of artificial intelligence based on sensor networks in student mental health support system and crisis prediction", *Measurement: Sensors*, vol. 32, s. 100 332, 2024. DOI: 10.1016/j.measen.2024.101056.

[25] Y. Zhao ja X. Shu, "Speech emotion analysis using convolutional neural network (CNN) and gamma classifier-based error correcting output codes (ECOC)", *Scientific reports*, vol. 13, nro 1, 2023. DOI: 10.1038/s41598-023-47118-4.

[26] Y. Yin, N. Jia ja C. J. Wakslak, "AI can help people feel heard, but an AI label diminishes this impact", *Proceedings of the National Academy of Sciences*, vol. 121, nro 14, 2024. DOI: 10.1073/pnas.2319112121.

[27] J. De Freitas, A. K. Uğuralp, Z. Oğuz-Uğuralp ja S. Puntoni, "Chatbots and mental health: Insights into the safety of generative AI", *Journal of Consumer Psychology*, vol. 34, nro 3, s. 481–491, 2024. DOI: 10.1002/jcpy.1393.

[28] D. Chicco ja G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation", *BMC Genomics*, vol. 21, nro 1, s. 6, 2020. DOI: 10.1186/s12864-019-6413-7.

[29] D. B. Olawade, O. Z. Wada, A. Odetayo, A. C. David-Olawade, F. Asaolu ja J. Eberhardt, "Enhancing mental health with Artificial Intelligence: Current trends and future prospects", *Journal of Medicine, Surgery, and Public Health*, vol. 3, s. 100 099, 2024. DOI: 10.1016/j.glmedi.2024.100099.