

Timi Salminen

TEKOÄLY APUNA MIELENTERVEYSONGELMIEN TUNNISTAMISESSA

Informaatioteknologian ja viestinnän tiedekunta
Kandidaatintutkielma
Maaliskuu 2023

TIIVISTELMÄ

Timi Salminen: Tekoäly apuna mielenterveysongelmien tunnistamisessa
Kandidaatintutkielma
Tampereen yliopisto
Tietojenkäsittelytieteiden tutkinto-ohjelma
Maaliskuu 2023

Tässä tutkielmassa selvitetään, kuinka tekoälyä voidaan käyttää apuna mielenterveysongelmien tunnistamisessa. Tarkoituksena on tutustua miten tekoäly käyttää eri syötteistä kerättyä dataa hyväkseen ja voiko se tuottaa luotettavia tuloksia kyseisellä menetelmällä kerätyllä datalla. Mielenterveyden häiriöt ovat kasvaneet viime vuosien aikana ja kuormittavat terveydenhuoltoa paljon. Tähän ongelmaan tekoäly voisi tarjota helpotusta ja vapauttaa resursseja enemmän sairauksien hoitoon, vähentämällä diagnosointiin käytettäviä henkilötunteja.

Tutkielma on kirjallisuuskatsaus, johon on haettu aineistoja, jotka käsittelevät sekä mielenterveyttä että tekoälyä. Aineistoa analysoitiin ensin löydettyjen tutkimusten otsikoiden perusteella ja sen jälkeen lukemalla tiivistelmät ja pohtimalla niiden perusteella, mitkä tutkimukset mahdollisesti vastaavat tutkimuskysymykseen. Tutkimuksia aiheesta löytyi paljon ja aiheen suosio tutkimuskohteena tuntuu olevan nousussa viimeisimpien vuosien aikana.

Aluksi tutkielmassa käydään läpi erilaisia koneoppimisen malleja ja algoritmeja, joita tutkimuksissa on sovellettu. Toisessa osassa avataan löydettyjä tutkimuksia ja niiden saavuttamia tuloksia. Tutkimuksissa dataa on kerätty esimerkiksi ihmisten aktiivisuudesta, tavasta puhua, Twitter viesteistä ja jo olemassa olevista terveystiedoista, sekä kaavakkeista, joihin on pyydetty täyttämään terveystietoja. Suurinta osaa näistä keinoista on helppo ottaa käyttöön lähes missä päin maailmaa tahansa.

Tutkielmassa havaittiin tekoälyn kykenevän tuottamaan luotettavia diagnooseja ja osassa tapauksissa jopa poimimaan joukosta henkilöitä, joilla riski sairastua masennukseen on suurentunut syystä tai toisesta, jo ennen masennuksen puhkeamista. Löydettyissä tutkimuksissa tuli myös ilmi mahdollisuus saada tekoälystä apua suunniteltaessa potilaille henkilökohtaista hoitosuunnitelmaa.

Avainsanat: algoritmit, ahdistus, masennus, koneoppiminen

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

Sisällysluettelo

1	Johdanto	1
2	Tutkimuksissa käytettyjä koneoppimisen menetelmiä	2
3	Erilaisia keinoja tunnistaa mielenterveysongelmia tekoälyn avulla.....	3
3.1	Ääneen pohjautuvat tunnistamisen keinot	4
3.2	Liikkeeseen pohjautuvat tunnistamisen keinot	5
3.3	Ihmisten omiin teksteihin perustuvia tunnistusmenetelmiä	6
3.4	Kyselyihin pohjaavat tunnistamisen keinot	7
3.5	Olemassaolevia terveystietoja hyödyntävät keinot	8
4	Keskustelu ja yhteenveto	9
	Lähdeluettelo.....	10

1 Johdanto

Tutkielman tarkoituksena on selvittää, millaista apua tekoälystä voitaisiin saada etsittäessä keinoja tunnistaa mielenterveysongelmia. Esimerkiksi ihmisten internettiin kirjoittamien tekstien perusteella, sekä analysoimalla erilaista kerättyä dataa, kuten puhetta tai liikkumista päivän aikana. Mielenterveysongelmien yleisyys ja matala hoitoprosentti herätti kysymyksen (World Health Organization, 2021), tunnistetaanko ongelmia tarpeeksi ja voitaisiinko siinä käyttää apuna tekoälyä.

Maailmassa arvioidaan olevan noin 280 miljoonaa masennusta sairastavaa ihmistä. Matalan ja keskitulon maissa masennusta kärsivistä ihmisistä alle 25 % saa siihen tarvitsemaansa hoitoa. Kun tarkastellaan masennusta kaikissa maissa tulotasosta riippumatta, masentunut henkilö usein saa diagnoosin jostakin muusta kuin masennuksesta ja vastaavasti masennusdiagnoosin saa moni, jolla ei masennusta esiinny (World Health Organization, 2021). Masennus ei siis ole harvinainen sairaus, mutta silti oikean diagnoosin saaminen vaikuttaa olevan hankalaa. Mikäli diagnosointiin voitaisiin saada apua tekoälystä, voisi yhä useampi saada itselleen tarpeellista hoitoa ja elää parempaa elämää.

Tutkielman aihe on elänyt ja mukautunut kirjoittamisen ja tiedonhaun myötä. Aihe on laajentunut pelkästä masennuksesta ja tekoälystä yleisesti mielenterveyteen ja tekoälyyn, sekä koneoppimiseen. Ennakkoon ei ollut tietoa onko aihetta tutkittu, ja jos on niin kuinka paljon. Pian kuitenkin tuli selväksi tutkimuksia olevan riittävästi kirjallisuuskatsauksen tekemiseksi valitusta aiheesta. Kaikissa mukaan otetuissa tutkimuksissa on saatu positiivisia tuloksia ja todetaan tekoälyn tuovan apua mielenterveysongelmien tunnistamiseen.

Tämä tutkielma on tehty kirjallisuuskatsauksena. Lähteiden etsiminen on toteutettu hakuterminä: ("artificial intelligence" OR "machine learning") AND ("depression" OR "mental health"), vastaavilla termeillä tehty haku suomen kielellä ei tuottanut tuloksia. Kyseinen englanninkielinen haku tuotti paljon tuloksia, osa tuloksista kuitenkin osoittautui jo otsikon perusteella käsittelevän jotakin, mikä ei tähän tutkielmaan sopinut. Tulosten suuren määrän johdosta myös soveltuvia lähteitä löytyi paljon. Moni tutkimus myös sisälsi lähteinä kiinnostavia tutkimuksia. Haut aloitettiin Tampereen yliopiston Andor-hakupalvelusta ja myöhemmin hakuja tehtiin myös ACM Digital Library ja Scopus -tietokantoihin.

Aineistoa on valittu hakujen tuottamasta joukosta lukemalla tutkimusten otsikot ja niiden ollessa osuvia on siirrytty lukemaan tiivistelmä. Mikäli tiivistelmä on osoittautunut lupaavaksi, on teos päässyt jatkoon ja kokonaan luettavaksi. Hyvin harva teksti karsiutui enää tässä vaiheessa. Lopullisesti aineistoksi päätyneistä lähteistä on pyritty löytämään keinot, joilla on lähestytty mielenterveyden ongelmien tunnistamista ja pyritty tuomaan ne omassa tutkielmassa esille.

Luvussa 2 esitellään lyhyesti tutkimuksissa käytettyjä koneoppimisen keinoja. Luvussa 3 esitellään erilaisia keinoja, joilla mielenterveysongelmia voidaan ennustaa pohjautuen erilaisiin datasyötteisiin, sekä tutkimuksen keskeiset tulokset. Luvussa 4 esitetään aiheesta yhteenveto.

2 Tutkimuksissa käytettyjä koneoppimisen menetelmiä

Bayesin luokitin (Bayes classifier) on suunniteltu tilastolliseen luokitteluun. Sen tarkoituksena on minimoida väärän kategorisoinnin mahdollisuus (Wikipedia, 2023).

Konvolutiivinen neuroverkko (Convolutional neural network, CNN) pohjaa syväoppimiseen, minkä pohjana on keinotekoisien hermojen luoma monikerroksinen neuroverkko. Yleisin käyttökohteita konvoluutiiviselle neuroverkolle on kuvien analysoiminen, muita käyttökohteita on esimerkiksi luonnollisen kielen käsittely ja suosittelujärjestelmät (Wikipedia, 2023).

Päätöspuu (Decision tree) on vuokaaviomainen työkalu, joka auttaa valitsemaan välivaiheet, joilla saavutetaan haluttu lopputulos. Käytetään koneoppimisen lisäksi myös esimerkiksi vakuutustoiminnassa, terveydenhuollossa (Wikipedia, 2023).

K:n lähimmän naapurin (K nearest neighbor, k-NN) menetelmää voidaan käyttää luokitteluun, jolloin tarkasteltava objekti sijoitetaan samaan luokkaan, kuin sen k lähintä naapuria. Toinen käytötapa on regressioanalyysi, jolloin objektille palautetaan jokin arvo, joka lasketaan k:n lähimmän naapurin vastaavan arvon keskiarvosta (Wikipedia, 2023).

Jätä-yksi-pois ristiin validointi (Leave-One-Out-Cross-Validation, LOOCL) menetelmässä otetaan vuorollaan yksi objekti koko datasta testattavaksi ja kaikkia muita objekteja käytetään harjoitusdatana. Tämä toteutetaan vuorollaan jokaiselle objektille yksi kerrallaan (Zach, 2023).

Logistinen regressio (Logistic regression) arvioi jonkin tapahtuman todennäköisyyttä asteikolla yhdestä nollaan. Logistista regressiota voidaan käyttää esimerkiksi ennustettaessa kuuluuko ihminen jonkin tietyn sairauden riskiryhmään (Swaminathan, 2018).

Monikerroksinen perseptroniverkko (Multilayer perceptron) sisältää vähintään kolme kerrosta. Ensimmäisenä syötekerros, sen jälkeen vähintään yksi piilokerros ja viimeisenä tuloskerros (Wikipedia, 2023).

Satunnainen metsä (Random forest) luokitin luo useita päätöspuita. Luokituksessa tulos on useimpien puiden valitsema luokka ja regressiossa paluuarvona saadaan puiden valintojen keskiarvo (Wikipedia, 2023).

Tukivektorikone (Support vector machine) on lineaarinen luokitinmalli. Tukivektorikoneen sovittaa näytejoukkojen väliin tason, jolle ei jää näytteitä ja reunoille muodostetaan tukivektorit (Wikipedia, 2023).

Kuvaaja neuroverkko (Graph neural network, GNN) on nimensä mukaisesti neuroverkko kuvaajien käsittelyä varten. Konvolutiivista neuroverkkoa voidaan ajatella kuvaaja neuroverkon tapauksena, jossa graafia käsitellään pikselimuotoon muutettuna kuvana varsinaisen graafin sijasta (Wikipedia, 2023).

3 Erilaisia keinoja tunnistaa mielenterveysongelmia tekoälyn avulla

Mukaan valitut tutkimukset sijoittuvat vuosien 2011 ja 2020 välille. Valtaosa tutkimuksista kuitenkin on vuonna 2018 tai sen jälkeen julkaistu. Jokaisessa mukaan valitussa tutkimuksessa ongelma on mielenterveysongelmien löytäminen datajoukosta seulotulla tiedolla. Tutkimukset lähestyvät asiaa samansuuntaisesta kulmasta ja yhtäläisyyksiä tavoissa löytyy, mutta jokainen ratkaisu on tästä huolimatta yksilöllinen ja juuri kyseiselle datajoukolle sopiva.

Thieme ja muut. (2020) listaavat tekoälyn mielenterveysongelmien tunnistamisen vahvuuksiksi helppouden, sopivuuden, sekä hienovaraisen keinon päästä käsiksi objektiiviseen ja skaalautuvaan dataan. Tekoäly voi syntetisoida informaatiota suuresta määrästä dataa lyhyessä ajassa ja paljastaa yksilöllisiä käyttäytymismalleja poikkeavuuksien löytämiseksi ja näin auttaa tunnistamaan ja hoitamaan sairauksia (Yang ja muut, 2020)

Tutkimuksia, joissa mielenterveyden ongelmia pyritään tunnistamaan tekoälyn avulla löytyy paljon. Tässä tutkielmassa keskitytään seuraavaksi viiteen mahdolliseen lähestymistapaan. Taulukossa 1 havainnollistetaan, millaista dataa on kerätty kutakin tutkimusta varten. Ensin käsitellään tutkimuksia, jotka etsivät poikkeavuuksia äänessä, joko irrallisissa lyhyissä minuutin pätkissä (Chang ja muut. 2011), tai eri tunnelmaa simuloivissa olosuhteissa (van den Broek ja muut. 2013). Toisena liikkeeseen pohjautuvaa havainnointia on tutkinut Frogner ja muut. (2019), liikkumista mittaavien laitteiden tuottaman datan ja koneälyn yhdistämisellä. DeMasi ja Recht (2017) puolestaan vastaavat tutkimuksessaan kysymykseen onko mahdollista ennustaa GPS-sijainnilla (Global Positioning System) kerätyn datan ja mielialakyselyiden perusteella onko ihmisellä energinen ja hyvinvoiva olo. Kolmantena käsitellään ihmisten itse tuottama teksti. Viestintäpalvelu Twitteriin käyttäjien lähettämiä viestejä on tutkittu Chenin ja muiden (2018) ja Joshin ja muiden (2018) toimesta. Keskustelupalsta Redditiä haettua dataa taas puolestaan analysoidaan Gaur ja muut (2018) tutkimuksessa. Neljäntenä Yang ja Bath (2019) keskittyvät tutkimuksessaan vanhuksiin ja soveltamaan koneoppimismalleja, joilla voitaisiin tehokkaasti ennustaa vanhusten riskiä sairastua masennukseen. Viidentenä Lu ja muut (2022) avaavat tutkielmassaan, kuinka jo olemassa olevia terveystietoja hyödyntämällä voidaan mahdollisesti ennustaa riskiä mielenterveysongelmiin.

Taulukko 1. Lähteiden analysoitava data.

Lähde	Ääni	Liike	Viestit	Kyselyt	Terveystiedot
Chang ja muut. (2011)	x				
van den Broek ja muut (2013)	x				
Frogner ja muut (2019)		x			
DeMasi & Recht (2017)		x			
Chen ja muut (2018)			x		
Joshi ja muut (2018)			x		
Gaur ja muut (2018)			x		
Yang & Bath (2019)				x	
Yang ja muut (2020)	x	x			
Thieme ja muut (2020)	x	x	x	x	
Lu ja muut (2022)					x

3.1 Ääneen pohjautuvat tunnistamisen keinot

Äänestä voidaan tarkkailla useaa eri muuttujaa. Näistä muuttujista voidaan luoda tietokoneelle malleja, joilla tunnistetaan poikkeavuuksia ja mahdollisesti huomataan henkilön sairaus. Lähteissä on tutkittu traumaperäisen stressihäiriön (von den Broek ja muut, 2019) ja masennuksen (Chang ja muut, 2011) tunnistamista eri kriteereillä luoduilla koneoppimisen malleilla. Käytettyjä muuttujia olivat muun muassa: äänen voimakkuus, tauot puheessa, äänen taajuus, puheen selkeys ja puhujan eloisuus.

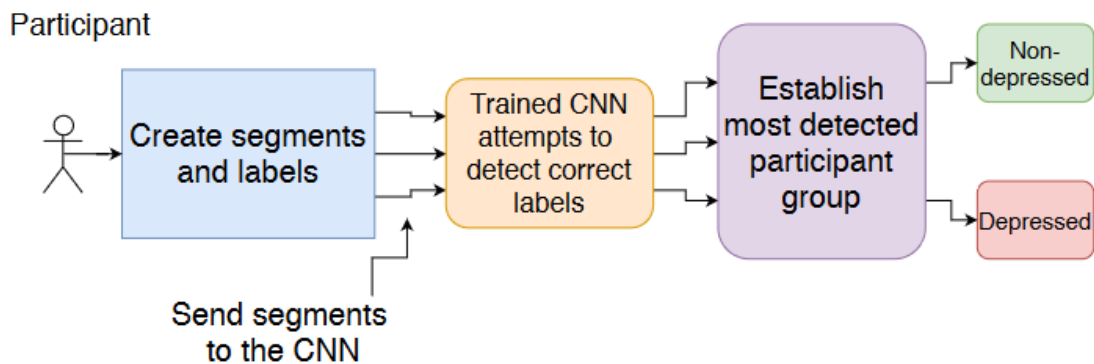
Tutkimuksessaan Chang ja muut (2011) esittävät ratkaisuksi ammattilaisten puutteeseen automaattista mielenterveyden seuranta esimerkiksi ihmisten puhelinkeskusteluihin tai yleiseen seurantaan muualla. Pitkäaikainen automaattinen äänen ajoittainen seuranta voisi auttaa tunnistamaan mahdollisen masennuksen syntyä tai pahenemista. Chang ja muut (2011) esittävät tutkimuksessaan psykiatrien ensin huomaavan ihmisten puheessa jotakin mielenkiintoista, mutta ajan kuluessa siihen totutaan ja se unohtuu ja näin ollen ei huomata mahdollista muutosta pitkän ajan kuluessa.

Van den Broek ja muut (2013) simuloivat tutkimuksessaan terapiassa käynnin alkua ja myöhempää käyntiä. Ensimmäistä käyntiä vastasi tilanne, jossa luettiin neutraali tarina ja myöhemmän käynnin stressaavampaa tunnelmaa haettiin käymällä läpi potilaan edellistä paniikkikohtausta. Näistä tilanteista luotiin malleja, joita vertailtiin kontrolliryhmään ja tutkittiin saatuja tuloksia verrattuna aiemmin käytössä olleisiin tapoihin. Hyviä tuloksia saavutettiin k:n lähimmän naapurin ja tukivektorikone

menetelmiä hyödyntäen, mutta monikerroksinen perseptroniverkko tuotti tulosten suhteen pettymyksen (van den Broek ja muut, 2013).

3.2 Liikkeeseen pohjautuvat tunnistamisen keinot

Frogner ja muut (2019) ovat tehneet tutkimusta, joka on jaettu kolmeen osaan. Ensimmäisessä osassa käsitellään heidän käyttämänsä konvoluutioneuroverkot kykyä tunnistaa, onko ihminen masentunut vai ei, pohjaten dataan ihmisen liikkumisesta. Konvoluutioneuroverkon toiminta havainnollistettuna kuvassa 1. Toisessa osassa tarkastellaan, voiko tekoäly oppia havaitsemaan masennuksen eri vakavuustasoja. Kolmannessa osassa tutkittiin osaako tekoäly määrittää yksilölle masennuksen vakavuuden. Kaksi ensimmäistä osaa tutkimuksesta saatiin suoritettua hyvin, ja tulokset olivat lupaavia, kuitenkin kolmas kohta ei vakuuttanut tutkijoita ja tulokset ovat heidän mukaansa korkeintaan lupaava alku tämän suuntaiselle tutkimukselle. Tutkimuksessa tuodaan kuitenkin esille mahdollisuus soveltaa jo luotuja menetelmiä yksilön seurantaan ryhmän sijasta. Tällä voitaisiin seurata esimerkiksi kaksisuuntaisen mielialahäiriön syklien vaihtelua ja helpottaa potilaan elämää sitä kautta (Frogner ja muut, 2019). Liikkeeseen pohjautuva analyysi voisi olla helppo implementoida ihmisten arkeen, sillä hyvin moni kantaa mukanaan gyroskoopin sisältävää laitetta (esimerkiksi kännykkä tai älykello) päivittäin, näin ollen dataa voitaisiin kerätä paljon, ilman suurempaa vaivaa.



Kuva 1. Kuinka tunnistetaan, onko henkilö masentunut vai ei, konvoluutioneuroverkon opettamisen jälkeen (Frogner ja muut, 2019).

DeMasi & Recht (2017) ovat tutkineet hieman erilaista liikettä ja sen kykyä ennustaa yksilön hyvinvointia. Heidän tutkimuksensa pohjaa älypuhelimien GPS (Global Positioning System)-sijainnin tuottamaan dataan, sekä kyselyihin tutkimuksen alussa, lopussa ja raportointiin kahdeksan viikon tutkimusjakson aikana. Päämääränä oli selvittää voiko GPS-sijainnin tuottaman datan perusteella ennustaa luotettavasti henkilön energia- ja hyvinvointitasoa. GPS-lähettimen tuottamasta datasta otettiin talteen muun muassa: koko tutkimuksen aikana vierailtujen paikkojen määrä, oletettu kotona vietetty aika,

liikkeelläolo aika, jokaiselta päivältä pienin mahdollinen ympyrä, jonka sisälle kaikki liikehdintä mahtui ja sisäinen kello (circadian rhythm). Jokaista tutkimukseen osallistunutta tutkittiin yksilöinä ja dataa analysoitiin logistisella regressiolla, satunnainen metsä luokittelijalla, sekä tukivektorikoneella ja täsmällisyyttä tuloksille haettiin käyttämällä jätä-yksi-ulos ristiin validointia.

3.3 Ihmisten omiin teksteihin perustuvia tunnistusmenetelmiä

Chen ja muut (2018) ovat mitanneet tutkimuksessaan ihmisten tunteita Twitter viestien perusteella. Tarkkailtavaksi on otettu kahdeksan eri tunnetta. Kuusi niin kutsuttua Ekmanin perustunnetta: viha, inho, pelko, ilo, suru ja yllätys (Ekman, 1994 viitattu Chen ja muut, 2018). Lisäksi mukaan otettiin myös häpeä, joka on myöhemmin lisätty Ekmanin listalle, sekä hämmennys. Hämmennyksen mukaan ottamista perusteltiin seuraavasti: se on hyvin yleinen tunne, vaikka hämmennyksellä on selkeitä tunteenomaisia piirteitä, se usein mielletään enemmän henkilön mielentilaksi kuin tunteeksi. Hämmennystä on otettu tutkimuksissa kuitenkin hyvin vähän huomioon, joten se päätettiin ottaa mukaan tutkimukseen, sen usein sisältämän negatiivisen tunnearvon takia. Lisäksi luotiin yhdeksäs parametri, yleinen tunteiden ilmaisu viesteissä. (Chen ja muut, 2018) Dataa analysoitiin aikasarja-analyysilla ja tähän edelleen sovellettiin koneoppimisen luokittimia. Parhaiten sopiviksi kyseiseen tehtävään todettiin seuraavat luokittimet: logistinen regressio, tukivektorikone, naiivi Bayesin luokitin, päätöspuu ja satunnainen metsä. Erittäin mielenkiintoinen havainto tutkimuksessa oli, että masentuneet käyttävät yhtä paljon positiivisia tunteita kuvaavia sanoja kuin verrokkit, mutta enemmän negatiivisia ja vihaa ilmaisevia ilmaisuja. Tulokset tutkimuksessa ovat hyvin lupaavia ennustamaan masennusta käyttäjällä, tai riskiä masennukseen sairastumiseen.

Toinen lähestymistapa Twitter-datan pohjalta mielenterveysongelmien löytämiseen keskittyy hyvin erilaisiin parametreihin. Joshi ja muut (2018) ottivat 14 eri parametria tarkasteltavaksi luodessaan omaa koneoppimismalliaan. Näitä parametreja oli muun muassa: ystävien määrä, seuraajat, viestien lähettämisaika, hashtagit ja käyttäjän tykkäykset. Tutkimuksessa muodostettiin kolme vaihetta. Ensimmäisessä otettiin 13 parametria, joilla koitettiin selvittää, kärsiikö viestin lähettäjä mahdollisesti masennuksesta. Toisessa vaiheessa käytettiin neljäntoista parametria, joka on viestien sisällön perusteella luotu luokittelu. Viimeisessä vaiheessa yhdistettiin molemmat aiemmat keinot ja tällä tavalla saavutettiin 89 % tarkkuus masennuksen tunnistamiseen.

Twitterissä ihmiset kirjoittavat yleensä omalla nimellä, joka saattaa vaikuttaa siihen mitä kaikkea on valmis julkisesti jakamaan. Reddit keskustelupalstalla kaikki kirjoittavat nimimerkillä ja tämä saattaa kannustaa jakamaan omia tuntemuksia ja oireita. Gaur ja muut (2018) ovat tehneet tutkimustaan analysoimalla jo aiemmin kerättyä materiaalia Redditiin keskustelualueilla, jotka ovat osallistujamäärältään suurimpia mielenterveyden ja päihdeiden väärinkäytön saralla. Tutkimuksen tavoitteena oli jaotella Redditiin

viestiketjujen aloituksia DSM-5 (Diagnostic and Statistical Manual of Mental Disorders 5th edition) mukaisesti luokkiin. Perinteisillä heuristiikoilla mitattuna väärin positiivisten osumien määrä on ollut 30 %, mutta käytetyillä metodeilla tuo luku saatiin tiputettua 2.5 %:iin (Gaur ja muut, 2018).

3.4 Kyselyihin pohjaavat tunnistamisen keinot

Vanhemmalla iällä riskiä sairastua masennukseen käsitellään Yang & Bathin (2019) tutkimuksessa. Dataa on kerätty English Longitudinal Study of Ageing kyselykaavakkeilla, joilla kartoitetaan yli 50-vuotiaiden englantilaisten ikääntymistä, sekä masennuskyselyllä ja muistia testaamalla. Saadut tulokset on jaoteltu viiteen eri ryhmään. Ensimmäinen ryhmä on väestötilastolliset ja taloudelliset muuttujat. Toinen ryhmä pitää sisällään sosiaaliset ja verkostolliset tiedot. Kolmannessa ryhmässä fyysinen terveys, sekä mahdolliset vammat. Neljännessä ryhmässä on elämäntyyliä käsittelevät tekijät. Viides ryhmä on kognitiiviset kyvyt. Näihin tietoihin sovellettiin viittä eri koneoppimisluokitinta (äärimmäinen gradienttitehostus, kevyt gradienttitehostus, Keras-pohjainen konvolutiivinen neuroverkko, vakioitu ahne metsä ja logistinen regressio) ja lopuksi tehtiin satunnaisen metsän luokittimella erilaisia yhdistelmiä saaduista tuloksista. Yhdistelmätulokset osoittautuivat tarpeettomiksi, sillä yksittäisillä luokittimilla saadut tulokset olivat hyvin toistensa kaltaisia. Kuvassa 2 äärimmäisen gradienttitehostuksen mukaan kymmenen vaikuttavinta tekijää arvioitaessa masennuksen riskiä ja kuvassa 3 vastaava lista kevyen gradienttitehostus-luokittimen tuloksena.

Rank	XGB
1	CASP-19 quality of life* Self-reported general health (HRS) Age UCLA: feel lonely Gait walk SWLS: satisfy with life Cognition: semantic verbal fluency UCLA-based loneliness*
10	CASP-19: look forward to each day Satisfaction with life scale (SWLS)*

Kuva 2. Merkittävimmät tekijät vanhusten masennusriskiä arvioitaessa, äärimmäinen gradienttitehostus (Yang & Bath, 2019).

Rank	LGB
1	CASP-19 quality of life* UCLA: feel lonely Self-reported general health (HRS) Cognition: semantic verbal fluency SWLS: satisfy with life Age Gait walk UCLA-based loneliness* SWLS: life is close to his/her ideal
10	CASP-19: look forward to each day

Kuva 3. Merkittävimmät tekijät vanhusten masennusriskiä arvioitaessa, kevyt gradienttitehostus (Yang & Bath, 2019).

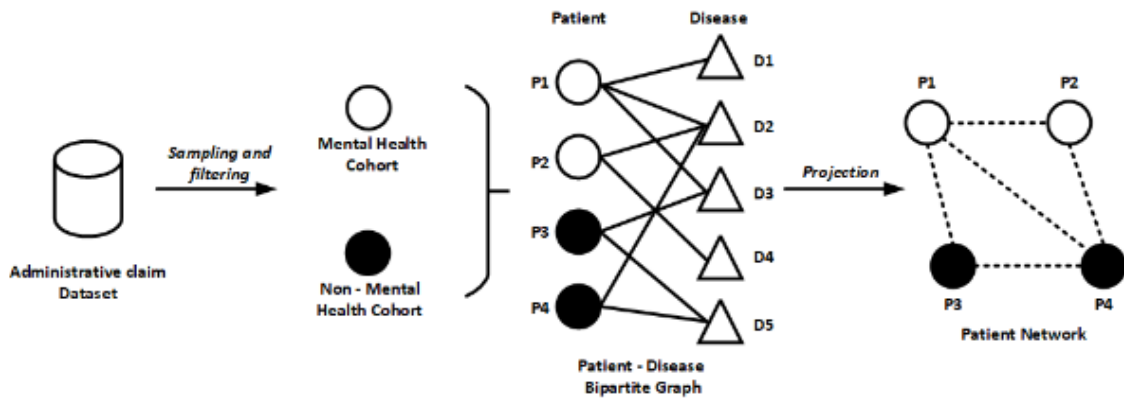
3.5 Olemassa olevia terveystietoja hyödyntävät keinot

Yksi lähestymistapa selvittää yksilön riskiä sairastua mielenterveyden ongelmiin, on selvittää voiko ongelmia ennustaa nykyisen terveystietojen pohjalta koneoppimisen avulla. Lu ja muut (2022) ovat tutkimuksissaan ottaneet tämän lähestymistavan ja saadut tulokset ovat olleet lupaavia.

Tutkimus on toteutettu Australiassa ja data on saatu yksityiseltä terveystietoyhtiöltä, joka saattaa aiheuttaa poikkeavan tuloksen koko kansaan verrattuna. Tutkimuksessa on otettu huomioon henkilöiden ikä, sukupuoli, tupakointi ja tautiluokitukset, muodostettaessa ennakoivaa mallia tulevista riskeistä.

Datajoukosta poimittiin ne, joilla on vähintään yksi mielenterveys sairaus ja yhtä suuri sattumanvarainen joukko henkilöitä, joilla kyseisiä sairauksia ei ole. Näille joukoille muodostettiin kaksijakoinen graafiprojektio potilas – tauti yhteyden perusteella. Tästä kaksijakoisesta joukosta muodostettiin edelleen uusi graafi, jossa eri sairauksien yhdistämät henkilöt linkittyvät toisiinsa. Kuvassa 4 prosessi kuvattuna visuaalisesti. Tutkimuksessa käytettiin hyväksi Elixhauser indeksiä, joka kertoo eri tautien oheissairastavuudesta.

Tutkittavana oli kolmen eri kuvaaja neuroverkon potentiaali, GCN:n (Graph convolutional network), GraphSAGE:n ja GAT:in (Graph attention network). Lu ja muut (2022) toteavat kuvaaja neuroverkojen tuottavan parempaa tarkkuutta mielenterveys ongelmien ennustamisessa, kuin perinteiset mallit. Kaikki valitut mallit tuottivat yli 85 % tarkkuuden, mutta GAT jopa yli 90 %.



Kuva 4. Potilasverkoston muodostaminen (Lu ja muut, 2022).

4 Keskustelu ja yhteenveto

Tekoäly voi auttaa meitä monin keinoin tunnistamaan mielenterveysongelmia tai jopa mahdollisesti riskiä niihin sairastumisesta. Ääneen, liikkeeseen (ihmisen liike, ihmisen liike suhteessa alueeseen), teksteihin ja erilaisiin kaavakkeisiin pohjautuville datajoukoille on löydetty keinoja seuloa riskitapaukset terveiden joukosta luotettavasti.

Tutkimuksissa ei tuotu esiin eettisiä näkökulmia lainkaan. Tämän näkökulman puuttuminen kokonaan herättää huolta aikana, jona tietoturvan ja yksilön oikeutta omaan dataan korostetaan. Monikaan käyttäjä tuskin tulee ajatelleeksi kirjoittaessaan viestiä Twitteriin tai Redditiin voivansa joutua osaksi esimerkiksi masennusta käsittelevää tutkimusta. GPS-seurantaa käyttävä tutkimus (DeMasi & Recht, 2019) oli toteutettu tutkijoiden tekemällä Android-sovelluksella, joten tässä tutkittavat olivat tietoisia seurannasta.

Saadut tulokset luovat uskoa parempaan masennuksen tunnistamiseen ja mahdollisesti aikaisempaan hoitoon hakeutumiseen. Tutkimuksia voitaneen soveltaa helposti suuremmillekin massoille, sillä useat tutkimukset on jo tehty suurille joukoille dataa ja skaalautuvuus ei todennäköisesti ole este. Lähes kaikki tutkimukset oli myös toteutettu joko välineillä, joita käytämme arjessa muutenkin (ääneen ja liikkeeseen pohjaavat tutkimukset) tai meidän muita tekemisiä analysoimalla (kirjoitukset ja kaavakkeet). Näin ollen vastaavaa voisi soveltaa lähes keneen vaan, joka elää samanlaisessa ympäristössä kuin tutkimus on toteutettu.

Teloälyä käyttämällä mielenterveystutkimuksessa voitaisiin tuoda ”yhteistä hyvää” ja pienentää merkittävästi sairauden ihmisille tuomaa henkilökohtaista taakkaa ja taloudellista kuormaa yhteiskunnalle. Tekoälyn avulla voitaisiin myös mahdollisesti luoda henkilökohtaista henkistä valmennusta ja tukea tarjoavia sovelluksia ja auttaa tekemään nykyisestä mielenterveyden hoidosta tehokkaampaa. (Thieme ja muut, 2020)

Jatkotutkimuksia varten DeMasi & Recht (2019) haluaisivat tuoda tutkimukseen enemmän parametrejä, esimerkiksi kiihtyvyyssmittarin GPS-mittarin rinnalle ja päästä näin enemmän selville päivän aktiivisuudesta. Reddit-viestien analysoinnissa koitetaan jatkossa tulkita paremmin negatiivista ja tutkia voidaanko samoja menetelmiä soveltaa Twitter-viesteihin (Gaur ja muut, 2018). Frogner ja muut, (2019) tuovat esiin toiveen datan monimuotoisuudesta tulevissa tutkimuksissa ja ehdottavat myös käytettäväksi takaisinkytkettyä neuroverkkoa ja Markovin mallia.

Tutkielmasta on myös voinut jäädä puuttumaan jotakin oleellisia lähteitä, johtuen käytettyjen hakusanojen suppeasta valikoimasta. Varsinkaan huomattavasti poikkeavia tuloksia esittäviä tutkimuksia ei lähteiden joukkoon osunut yhtäkään.

Tutkielman tarkoitus oli selvittää kuinka tekoäly voi auttaa meitä tunnistamaan mielenterveysongelmia erilaisin keinoin. Tässä tutkielmassa on esitetty tuohon kysymykseen vastauksia useammasta eri tavasta. Tutkimuskohteena aihe tuntuu olevan nousussa ja kiinnostavan tutkijoita. Kaikkiaan tutkimustulokset ovat olleet lupaavia. Kaiken kattavaa apua tekoäly ei kuitenkaan tällä hetkellä ongelmiin tarjoa, mutta se osoittaa potentiaalia tuoda lisäarvoa perinteisen hoidon ja diagnosoinnin rinnalle.

Lähdeluettelo

- Chang, K., Chan, M., Canny, J. (2011). AnalyzeThis: unobtrusive mental health monitoring by voice. *CHI EA '11: CHI '11 Extended Abstracts on Human Factors in Computing Systems*. <https://doi.org/10.1145/1979742.1979859>
- Chen, X., Sykora, M. D., Jackson, T. W., & Elayan, S. (2018). What about mood swings: identifying depression on Twitter with temporal measures of emotions. *Companion Proceedings of the The Web Conference 2018*, 1653–1660. <https://doi.org/10.1145/3184558.3191624>
- DeMasi, O., & Recht, B. (2017). A step towards quantifying when an algorithm can and cannot predict an individual's wellbeing. *Proceedings of the 2017 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2017 ACM International Symposium on Wearable Computers*, 763–771. <https://doi.org/10.1145/3123024.3125609>
- Frogner, J. I., Noori, F. M., Halvorsen, P., Hicks, S. A., Garcia-Ceja, E., Torresen, J., & Riegler, M. A. (2019). One-dimensional convolutional neural networks on motor activity measurements in detection of depression. *Proceedings of the 4th International Workshop on Multimedia for Personal Health & Health Care*, 9–15. https://www.duo.uio.no/bitstream/handle/10852/69079/JoakimIhleFrogner_Master.pdf
- Gaur, M., Kursuncu, U., Alambo, A., Sheth, A., Daniulaityte, R., Thirunarayan, K., & Pathak, J. (2018). "Let me tell you about your mental health!": Contextualized classification of Reddit posts to DSM-5 for web-based intervention. *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, 753–762. <https://doi.org/10.1145/3269206.3271732>

- Joshi, D. J., Makhija, M., Nabar, Y., Nehete, N., & Patwardhan, M. S. (2018). Mental health analysis using deep learning for feature extraction. *Proceedings of the ACM India Joint International Conference on Data Science and Management of Data*, 356–359. <https://doi.org/10.1145/3152494.3167990>
- Lu, H., Uddin, S., Hajati, F., Khushi, M., & Moni, M. A. (2022). Predictive risk modelling in mental health issues using machine learning on graphs. *Australasian Computer Science Week 2022*, 168–175. <https://doi.org/10.1145/3511616.3513112>
- Swaminathan, S. (15.3.2018). *Logistic regression – detailed overview*. <https://towardsdatascience.com/logistic-regression-detailed-overview-46c4da4303bc>
- Thieme, A., Danielle, B., and Gavin, D. (2020). 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* 27(5), 34. <https://doi.org/10.1145/3398069>.
- van den Broek, E. L., van der Sluis, F., & Dijkstra, T. (2013). Cross-validation of bimodal health-related stress assessment. *Personal and Ubiquitous Computing*, 17(2), 215–227. <https://doi.org/10.1007/s00779-011-0468-z>
- Wikipedia. *Bayes classifier*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/Bayes_classifier
- Wikipedia. *Convolutional neural network*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/Convolutional_neural_network
- Wikipedia. *Decision tree*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/Decision_tree
- Wikipedia. *Graph neural network*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/Graph_neural_network
- Wikipedia. *K-nearest neighbors algorithm*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm
- Wikipedia. *Multilayer perceptron*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/Multilayer_perceptron
- Wikipedia. *Random forest*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/Random_forest
- Wikipedia. *Support vector machine*. Haettu 3.3.2023 osoitteesta https://en.wikipedia.org/wiki/Support_vector_machine
- World Health Organization (13.9.2021), *Depression*. Haettu 16.10.2022 osoitteesta <https://www.who.int/news-room/fact-sheets/detail/depression>
- Zach. (3.11.2020). *A quick intro to leave-one-out cross-validation (LOOCV)*. <https://www.statology.org/leave-one-out-cross-validation/>
- Yang, H., & Bath, P. A. (2019). Automatic prediction of depression in older age. *Proceedings of the 3rd International Conference on Medical and Health Informatics*, 36–44. <https://doi.org/10.1145/3340037.3340042>

Yang, F., Han, T., Deng, K., & Han, Y. (2020). The Application of artificial intelligence in the mental diseases. *Proceedings of the 2020 Conference on Artificial Intelligence and Healthcare*, 36–40. <https://doi.org/10.1145/3433996.3434004>