

Kohti kestävämpää mielen hyvinvointia työssä

KONEOPPIMINEN JA MIELENTERVEYSTAPAHTUMIEN ENNAKOINTI

Pekka Varje
Tiina Kalliomäki-Levanto
Jussi Turtiainen
Olli Haavisto
Ilkka Kivimäki
Maksim Mustakallio
Ari Väänänen

Kohti kestävämpää mielen hyvinvointia työssä

Koneoppiminen ja mielenterveystapahtumien ennakointi

Pekka Varje, Tiina Kalliomäki-Levanto, Jussi Turtiainen, Olli Haavisto, Ilkka Kivimäki,
Maksim Mustakallio ja Ari Väänänen

Työterveyslaitos

Työkyky ja työurat

PL 40

00251 Helsinki

www.ttl.fi

© 2022 Työterveyslaitos ja kirjoittajat

Hanke on toteutettu Työsuojelurahaston tuella.

Tämän teoksen osittainenkin kopiointi on tekijänoikeuslain (404/61, siihen myöhemmin tehtyine muutoksineen) mukaisesti kielletty ilman asianmukaista lupaa.

ISBN 978-952-391-026-3 (PDF)

Tiivistelmä

Mielenterveysongelmat muodostat suomalaiselle työelämälle merkittävän haasteen työkyvyttömyyden keskeisimpänä aiheuttajana. Mielenterveysongelmien ennaltaehkäisyyn kannalta on tärkeää lisätä ymmärrystä ongelmien taustalla olevista tekijöistä ja kehittää menetelmiä niiden ennakointiin. Tutkimushankkeessa *Paremmalla ennakoinnilla kestävämpään mielen hyvinvointiin työssä* tavoitteena on ollut 1) tuottaa digitaalisiin potilasasiakirja-aineistoihin perustuvaa tietoa työntekijöiden mielenterveysongelmien ja unio ongelmien kehityksestä sekä taustatekijöistä ja 2) valjastaa koneoppimisen tarjoamat välineet työterveystutkimuksen ja työntekijöiden psyykkisen hyvinvoinnin muutosten ennakkoinnin edistämiseen.

Tutkimusaineistona käytettiin Terveystalon työterveyshuollon rekisteripohjaista pitkitäisaineistoa. Se koostui mielenterveyteen liittyvistä taustatiedoista (ikä, sukupuoli), diagnoositiedoista, työterveyskyselyistä sekä lääkärin kirjaamista hoitokertomusteksteistä. Aineiston analyysit perustuivat havaintoihin kymmenistä tuhansista työntekijöistä usean vuoden ajalta. Ensimmäisessä tutkimusasetelmassa ennustimme työntekijän saamaa ensimmäistä mielenterveysdiagnoosia käyttäen työterveyskyselyä. Toisessa asetelmassa ennakoimme hoidon pitkittymistä käyttämällä hoitoprosessin alussa kertyneitä hoitokertomustekstejä materiaalina. Analyyseissä hyödynsimme ennustavaa luokittelumallinnusta sekä aihe mallinnusta.

Luokittelumallinnus kykeni ennustamaan ensimmäisen mielenterveysdiagnoosin saamisen selvästi paremmin kuin satunnaisluokittelija. Työterveyskyselystä nousi esiin seitsemän keskeisintä piirrettä, joiden luokittelukyky oli lähes yhtä hyvä kuin kaikkien yli sadan kysymysten mallissa. Luokittelun kannalta tärkeimmät kysymykset liittyivät stressiin, surumielisyyteen ja väsymykseen. Yhtä hyvään luokittelukykyyn pääsimme ennustettaessa mielenterveyteen liittyvän hoitajakson pitkittymistä yli neljään lääkärikäyntiin hoitajakson alussa ensimmäisellä ja toisella käyntikerralla kirjattujen tekstien perusteella. Etenkin masennukseen, sen lääkinälliseen hoitoon ja uupumukseen, terapian hakemiseen, perheen tilanteeseen, työolosuhteisiin tai hoidon jatkuvuuteen liittyvät aiheet teksteissä sekä alkuvaiheessa diagnosoitu masennus ja ahdistuneisuushäiriö ennustuvat pitkittyneempää mielenterveyden hoidon tarvetta.

Koneoppimiseen perustuen hankkeessa onnistuttiin automaattisesti seulomaan aineistoista mielenterveysdiagnoosia tai mielenterveyden hoitosarjan pitkittymistä ennustavia piirteitä ja tuottamaan mielenterveystapahtumia ennustavia mallinuksia, vaikka koneoppimisen käytössä tunnistettiin selkeitä rajoituksia. Käytetyt lähestymistavat saattavat jatkossa osoittautua hyödyllisiksi sekä psyykkisen työkyvyn tutkimuksessa että käytännön ennaltaehkäisyyn ja hoitotyön tukena.

Abstract

Mental health problems constitute a significant burden for Finnish work life as a major cause for work disability. For preventing mental health problems, it is important to increase the knowledge on the background factors behind mental health problems and to develop predictive tools. In our research project *Predictive models to support mental wellbeing at work* the aim has been to 1) produce new knowledge on the background factors and development of mental disorders among employees and to 2) create AI-based predictive models that facilitate the early recognition mental health problems.

As our research data we utilized occupational health care -related longitudinal register-based materials collected from Terveystalo, the largest private health care service provider in Finland. The materials consisted of demographic background information, mental health -related diagnoses, occupational health questionnaires and treatment reports written by physicians. The analyses were based on tens of thousands of cases over several years. In the first study design we predicted the first mental health -related diagnosis based on the occupational health questionnaire. In the second study design we predicted the prolongation of the treatment based on the treatment reports written in the beginning of the treatment process. In the analyses we utilized predictive classification modelling and topic modelling.

The classification model was able to predict the first mental health -related diagnosis clearly better than a random classifier. The questionnaire included seven questions that had nearly the same predictive ability as all the over one hundred questions combined. The most important questions were related to stress, sadness, and fatigue. The classifier that predicted the prolongation of the treatment series to over four physician visits based on the texts in the first two treatment reports reached a similar predictive capacity as well. The most important predictors included topics related to depression, the pharmaceutical treatment of depression, burnout, therapy-related considerations, family situation, working conditions and the continuation of treatment. Diagnoses related to depression and anxiety disorders at baseline also predicted prolonged mental health treatment.

Using machine learning, we were able to automatically screen factors that predict mental health -related diagnosis or the prolongation of the treatment series from a large digital database and to create models that predict mental health -related events, although there were clear limitations to the predictive ability of the models. The approaches we used may turn out to be widely useful in other research on occupational health as well as in supporting practical healthcare.

Sisällys/Table of contents

Tiivistelmä.....	3
Abstract	4
Sisällys/Table of contents.....	5
1 Hankkeen lähtökohta	7
2 Menetelmät	9
2.1 Teoreettiset lähtökohdat.....	9
2.2 Aikaisempi kirjallisuus.....	10
2.3 Tutkimusaineistot.....	13
2.3.1 Kysely- ja diagnoosiaineisto	13
2.3.2 Hoitokertomustekstiaineisto	14
2.4 Tutkimusasetelma ja menetelmät.....	16
2.4.1 Tutkimusasetelma	16
2.4.2 Kyselyaineistoon perustuvat analyysit	18
2.4.3 Hoitokertomusteksteihin perustuvat analyysit.....	18
2.4.4 Tulosten arviointi.....	22
2.5 Tutkimuseettiset näkökohdat.....	23
3 Päätulokset	25
3.1 Mielenterveysdiagnoosin ennustaminen terveystieteeseen perustuen	25
3.1.1 Mallien suorituskyky	25
3.1.2 Vastausmuuttujien merkitsevyys ennusteen kannalta	27
3.2 Hoitokertomustekstien aihehallinnus.....	29
3.2.1 Työterveyshuollon mielenterveyden tukeen liittyvät aiheet	29
3.2.2 Esimerkki teema-aiheiden kehittymisestä.....	34
3.2.3 Aiheet hoidon pitkeyden ennustajina.....	35
3.2.4 Aihehallinnuksella saadun tiedon luotettavuus ja rajoittavat tekijät.....	37
3.2.5 Aihehallinnuksen mahdollisuudet.....	37
4 Yhteenveto	39

5	Lähteet.....	43
	LIITTEET.....	48

1 Hankkeen lähtökohta

Mielenterveysongelmat muodostavat merkittävän taloudellisen ja sosiaalisen haasteen niin yksilöille, työorganisaatioille kuin koko yhteiskunnallekin (OECD, 2018). Ne ovat vahvassa yhteydessä työkyvyttömyyteen ja sairauspoissaoloihin. Mielenterveysongelmat nousivat vuonna 2019 suurimmaksi uusien työkyvyttömyyseläkkeiden perusteeksi (Laaksonen et al., 2021). Kun kaikki Kelan korvaamat sairauspoissaolot otetaan huomioon, mielenterveysperusteiset poissaolot aiheuttavat Suomessa suhteellisesti eniten sairauspoissaolopäiviä ja niiden osuus on ollut kasvussa viime vuodet (Blomgren & Perhoniemi, 2021). Taloudellisen ja sosiaalisen kestävyuden kannalta olisi keskeistä pyrkiä kehittämään mielenterveysongelmien taustalla olevia tekijöitä koskevaa ymmärrystä sekä rakentaa uusia välineitä mielenterveysongelmien ennakointiin ja ennaltaehkäisyyn (Chisholm, 2016).

Työterveyslaitoksella toteutetussa ja Työsuojelurahaston rahoittamassa (rahoituspäätös 190402) tutkimushankkeessa *Paremmalla ennakoinnilla kestävämpään mielen hyvinvointiin työssä* olemme pyrkineet kehittämään uudenlaista aineistolähtöistä työväestön mielenterveyden tutkimusta sekä luomaan työkaluja työterveyshuollon toiminnan tukemiseksi. Tavoitteenamme on ollut tuottaa tietoa mielenterveyden diagnooseja sekä mielenterveyteen liittyvän hoidon pitkittymistä ennustavista tekijöistä ja luoda ennustemalleja, jotka voivat vahvistaa työterveyden asiantuntijoiden mahdollisuuksia tarjota varhaista tukea mielenterveysongelmien hoidossa.

Hanke on edustanut monelta osin uudentyypeistä lähestymistapaa mielenterveyden tutkimukseen. Erilaisten työssä käyvien väestöryhmien mielenterveyttä sekä työhön liittyviä psykososiaalisia riskitekijöitä on tutkittu vuosikymmenten ajan, mutta valtaosa olemassa tiedosta on perustunut perinteisiin hypoteesilähtöisiin tilastomenetelmiin sekä rakenteellisessa muodossa oleviin kyselyaineistoihin (Väänänen et al., 2012). Viimeisten vuosien nopea kehitys tietotekniikassa ja datatieteissä on kuitenkin tuonut tarjolle aivan toisenlaisia lähestymistapoja (Wu et al., 2014). Koneoppiminen on mahdollistanut valtavien digitaalisten aineistojen tehokkaan aineistolähtöisen hyödyntämisen riippumatta siitä, onko aineisto lähtökohtaisesti rakenteellisessa muodossa vai edustaako se luonnollista kieltä (McIntosh et al., 2016). Tämä tutkimushanke perustuu ajatuksen siitä, että koneoppimisen ja uudentyypeisten digitaalisten aineistojen hyödyntäminen voi merkittäväällä tavalla edistää työssä käyvän väestön mielenterveyden tutkimusta. Lisäksi olemme lähteneet tarkastelemaan siihen liittyviä mahdollisuuksia, kuinka koneoppimisen keinoin kehitettyjä aineistolähtöisiä lähestymistapoja voisi hyödyntää työterveyshuollon mielenterveyttä tukevassa toiminnassa 2020-luvulla.

Tutkimuksen perustana olemme käyttäneet työterveyshuollon tuottamia tai työterveyshuollon piirissä kerättyjä digitaalisia aineistoja, joita on käsitelty aineistolähtöisesti koneoppimisen menetelmiä hyödyntäen. Hankkeen tutkimuskysymykset ovat olleet 1) mitkä tekijät ennustavat mielenterveysongelmia ja uniongelmiä suomalaisessa työssä käyvässä väestössä, 2) mitkä tekijät ennustavat mielenterveyteen ja uniongelmiin liittyvän hoitoketjun pitkittymistä työssä käyvässä väestössä ja 3) millä tarkkuudella työterveyshuollon aineistoista voidaan ennustaa mielenterveyden diagnoosia tai hoidon pitkittymistä koneoppimisen menetelmiä hyödyntäen? Näiden tutkimuskysymysten rinnalla olemme keränneet tietoa siitä, mitä erilaista tietoa potilasasiakirjoista voidaan saada koneoppimista hyödyntäen ja mitkä tekoälyalgoritmit sopivat tehtävään parhaiten. Näihin kohtiin liittyvä tieto on keskeistä suunniteltaessa uusia datalähtöiseen mielenterveyden tutkimukseen liittyviä hankkeita.

Tutkimushankkeemme toteutettiin 1.2.2020–31.7.2022 yhteistyössä Terveystalon sekä Helsingin yliopiston kanssa. Hankkeen vastuuhenkilönä toimi tutkimuspäällikkö Pekka Varje ja hänen varahenkilönään tutkimusprofessori Ari Väänänen. Hankkeen tutkijoina sisältökysymysten osalta toimivat erikoistutkija Tiina Kalliomäki-Levanto ja tutkija Jussi Turtiainen. Hankkeen menetelmällisinä asiantuntijoina toimivat erityisasiantuntijat Ilkka Kivimäki sekä Olli Haavisto. Menetelmällisiin kysymyksiin antoi lisätukea vanhempi asiantuntija Aki Koskinen ja hankkeen kirjallisuushakuihin osallistui asiantuntija Maksim Mustakallio. Hankkeen viestinnän vastuuhenkilönä toimi erityisasiantuntija Tiina Kaksonen. Hankkeen valmisteluun ja alkuvaiheisiin osallistuivat lisäksi tuotepäällikkö Riku Louhimo, erityisasiantuntija Teemu Okkonen sekä johtava tutkija Anssi Smedlund.

Yhteistyöhön ovat osallistuneet kehitysjohtajat Ilari Richardt ja Karita Reijonsaari, johtava epidemiologi Simo Taimela, tiimiesimies Oskar Niemenoja sekä datatieteilijät Niina Nieminen ja Ara Taalas. Kiitos kuuluu myös hankkeen ohjausryhmälle, johon osallistivat Valtioneuvoston Kanslian ja Kansallinen Ennakointiverkoston (KEV) edustajana erityisasiantuntija Kaisa Oksanen, Suomen Työterveyslääkäriyhdistys ry:n edustajana työterveyden ylilääkäri Minna Pihlajamäki sekä Mieli ry:n edustajana johtaja Meri Larivaara. Arvokasta menetelmällistä konsultaatiotukea hankkeelle tarjosi Helsingin yliopiston apulaisprofessori Eetu Mäkelä. Työsuojelurahaston edustajana hankkeen valvojana toimi toimitusjohtaja Kenneth Johansson. Kiitämme kaikkia hankkeen toteuttamiseen osallistuneita henkilöitä. Hanke ei olisi ollut mahdollista toteuttaa ilman Terveystalolta saatua kiinteää tukea ja useiden asiantuntijoiden yhteistyötä.

2 Menetelmät

2.1 Teoreettiset lähtökohdat

Koneoppimisen mahdollisuuksia käsittelevässä kirjallisuudessa on tunnistettu sen sisältämä uudenlainen potentiaali mielenterveyden tutkimukselle ja käytännön hoitotyölle. On ehdotettu, että tietokoneiden laskentatehon täysimääräinen hyödyntäminen voisi tuoda merkittäviä parannuksia sairauksien taustatekijöiden kartoittamiseen, ennakointiin, varhaiseen tunnistamiseen ja hoidon suunnitteluun (Russ ym., 2019). On myös havaittu, että koneoppimisen menetelmiä voisi olla mahdollista hyödyntää esimerkiksi uusien teoreettisten mallien tuottamisessa ja aineistolähtöisessä interventioiden suunnittelussa, joka voisi tarkoittaa esimerkiksi automaattista työuupumusriskin varhaista tunnistamista (Grzadzielewska, 2021).

Useista lupaavista esimerkeistä huolimatta koneoppimisen hyödyntäminen mielenterveyden tutkimuksessa on kuitenkin melko alkuvaiheessa. Esimerkiksi stressitutkimuksen osalta on todettu olemassa olevan kirjallisuuden monet rajoitteet sekä vähäinen vaikutus työstressiä koskevan tutkimuksen kentällä (Hashmi & Yadav, 2018). Myös saavutukset uusia "big data" -lähteitä hyödyntävien käytännön sovellusten alueella ovat toistaiseksi jääneet vähäisiksi, vaikka tekoälyä monissa palvelujärjestelmissä hyödynnetäänkin (Tiffin & Paton, 2018).

Olemassa olevaa alan tutkimusta arvioitaessa huomio kiinnittyy mielenterveyden varsin vaihtelevaan määrittelyyn. Pieni vähemmistö tutkimuskirjallisuudesta keskittyy kliinisesti todettuihin mielenterveysdiagnooseihin ja selkeän enemmistön muodostavat ne tutkimukset, joissa on hyödynnetty erilaisia subjektiivisen hyvinvoinnin mittareita, kuten itsearvioitua työstressin tai työuupumuksen kokemusta (ks. Martin ym., 2019). Kliininen potilasaineisto on ilmeisen haastavaa saada tutkimuskäyttöön ja siksi sitä on hyödynnetty vähän. Epidemiologisen tutkimuksen näkökulmasta terveydenhuollon tuottamien aineistojen laajempi hyödyntäminen työväestön mielenterveyden tutkimuksessa olisikin erittäin hyödyllistä.

Tutkimuskirjallisuudesta löytyy kuitenkin useita kiinnostavia esimerkkejä koneoppimisen hyödyntämisestä mielenterveyden ja henkisen hyvinvoinnin tutkimuksessa. Koneoppimista on käytetty esimerkiksi tunnistamaan sairauksia ja ryhmittelemään potilaita oireiden perusteella terveydenhuollon tuottamista potilasasiakirjoista (Jackson ym., 2017; Koleck ym., 2019). Menetelmiä on käytetty myös ennustamaan mahdollisia mielenterveysongelmia sellaisista aineistoista kuin Facebook-kirjoitukset tai muut vastaavat tutkimushenkilöiden itsetuottamat tekstit (Eichstaedt ym., 2018; He ym., 2012).

Näistä tutkimuksista nousee esiin kolme koneoppimiseen liittyvää keskeistä ominaisuutta, jotka ovat vaikuttaneet myös omaan tutkimukseemme. Ensimmäinen niistä on aineistolähtöisyys. Vastoin perinteisen tilastotieteellisen tutkimuksen yleistä periaatetta koneoppimiseen perustuva tutkimus ei edellytä etukäteen muotoiltuja hypoteeseja tai huolellisesti valittua muuttujien joukkoa. Malliin, koneoppisen matemaattiseen perustyökaluun, voidaan syöttää lukemattomia ulottuvuuksia sisältävä valtava aineisto, josta algoritmi poimii vastemuuttujan kannalta olennaiset tekijät ja sulkee pois merkityksettömät tekijät. Siten sen etu perinteisiin tilastomenetelmiin verrattuna on tehokkuus piilevien ja yllättävien yhteyksien etsimisessä.

Toinen koneoppimisen erityispiirre koskee sen helppoa sovellettavuutta ennustaviin analyyseihin. Koneoppimisessa käytettävät itse itseään opettavat luokittelijat soveltuvat lähtökohtaisesti erittäin hyvin binäärisen vastemuuttujan arvon ennustamiseen monimutkaistenkin taustamuuttujien perusteella. Mikäli relevanttia muuttujamassaa on riittävästi, voidaan laatia ennusteita esimerkiksi siitä, saako yksittäinen henkilö diagnoosin annetulla aikavälillä. Ennusteen tarkkuutta voidaan samalla arvioida, kun käytettävissä on suuri tutkimusväestö.

Kolmas koneoppimisen erityispiirre koskee mallien kykyä hyödyntää perinteisten rakenteellisessa muodossa olevien aineistojen ohella luonnollista, ihmisten tuottamaa tekstiä. Luonnollisen kielen prosessoinnin kautta on mahdollista analysoida sellaisia valtavia tekstimassoja, joiden analysointi muulla tavoin vaatisi kohtuuttoman työmäärän (Kao & Poteet, 2007). Luonnollisen kielen prosessointia hyödyntäen on aikaisemmassa tutkimuksessa voitu tunnistaa vapaamuotoisesta tekstiaineistosta tunnetiloja sekä mielen-terveysongelmiin viittavia oireita ja hyödyntää niitä esimerkiksi ennustemallinnuksiin (Hirschberg & Manning, 2015; Karystianis ym., 2018).

Omissa analyyseissämme olemme hyödyntäneet sekä perinteistä rakenteellisessa muodossa olevaa kyselyaineistoa että vapaamuotoista tekstiaineistoa aineistolähtöisessä työväestön mielen-terveyden tutkimuksessa. Aineistolähtöisyys, luonnollisen kielen prosessointi sekä ennustemallinnukset ovat mahdollistaneet sekä kokonaan uudentyypin aineiston hyödyntämisen että uuden tiedon etsimisen perinteisemmästä aineistosta. Kokonaisuudessaan tutkimushanke pyrkii avaamaan vähän hyödynnettyjä tai jopa kokonaan uusia polkuja työhön liittyvän mielen-terveyden tutkimuksen alueella.

2.2 Aikaisempi kirjallisuus

Osana hanketta kartoitimme sen kansainvälisen tutkimuskirjallisuuden, jossa koneoppimisen menetelmiä on hyödynnetty työssä käyvän väestön mielen-terveyden

tutkimukseen. Koneoppimisen menetelmien hyödyntämistä terveystieteissä on kartoitettu aikaisemmissa kirjallisuuskatsauksissa (esim. Vahteristo & Kinnunen, 2019), mutta näiden huomio ei ole ollut työhön liittyvässä mielenterveydessä ja työkyvyssä.

Hakujen kautta löysimme kaikkiaan 14 kriteerit täyttävää tutkimusjulkaisua, joiden laatu oli riittävä tarkempaa analyysiä varten. Lähestyimme artikkeleita integroivan kirjallisuuskatsauksen periaatteiden kautta, joissa tarkoituksena on artikkeleiden kriittinen ja syn-
tetisoiva tarkastelu (Torraco, 2005). Haut tehtiin hyödyntäen Google Scholar -palvelua, joka on todennäköisesti laajin saatavilla oleva tietokanta valitun aiheen näkökulmasta (Halevi ym., 2017).

Kirjallisuushaut osoittivat, että koneoppimista on hyödynnetty työhön liittyvän mielen-
terveyden tutkimukseen vasta viime vuosista alkaen ja alue on tällä hetkellä laajene-
massa. Vanhimmat julkaisut ovat vuodelta 2010, mutta suurin osa julkaisuista on ilmes-
tynyt vasta vuodesta 2018 alkaen.

Tunnistamamme julkaisut on esitetty taulukossa 1. Kuten taulukko osoittaa, kenttää hallitsevat rakenteellisessa muodossa oleviin kyselyaineistoihin perustuvat tutkimukset. Tämä tarkoittaa käytännössä tutkimuksia, joissa on pääsääntöisesti hyödynnetty luokiteltuja muuttujia kuin perinteisessä tilastollisessa tutkimuksessa (esim. kyselyvastaukset), mutta koneoppimisen lähestymistapoja hyödyntäen. Tekstimuotoista luonnollisesti muotoutunutta ei-rakenteellista aineistoa hyödynnettiin vain yhdessä tutkimuksessa, jossa etsittiin luonnollisen kielen prosessoinnin työkaluilla työstressiin viittavia ilmaisuja miljoonista Twitter-julkaisuista ja tunnistettiin tähän liittyviä viikoittaisia trendejä (Wang ym., 2016).

Yleisimmät tutkitut vastemuuttajat liittyivät työstressiin, masennusoireisiin, työuupumukseen tai yleisempään psyykkiseen oireiluun. Yhdessäkään julkaisuista ei hyödynnetty kliinisesti määriteltyjä diagnooseja, vaan vastemuuttajat perustuivat kyselyaineistojen itsearviointikysymyksiin.

Oli merkille pantavaa, ettei yhdessäkään neljästätoista tutkimuksesta hyödynnetty epidemiologiselle tutkimukselle tyypillistä pitkittäisasetelmaa, jossa ennustavat tekijät edeltävät ajallisesti tutkimuskohteena olevaa tapahtumaa (kuten psykiatrissa diagnoosia tai alkanutta hoitojaksoa). Useimmat julkaisuista hyödynsivät koneoppimiseen perustuvia ennustemallinnuksia, mutta ennustettava vastemuuttuja oli osa samaa kyselyä kuin ennustavat tekijätkin. Näin useimmissa tutkimuksissa jäi epäselväksi, olivatko esimerkiksi heikot työolot aiheuttaneet psyykkistä oirehtimista, vai oliko kenties psyykinen oirehtiminen johtanut kokemuksiin siitä, että työolot ovat heikolla tolalla.

TUTKIMUS	AINEISTO	VASTEMUUTTUJA
Arkaprabha & Ishita (2019)	työpaikkakysely	masennus- ja ahdistusoireet
Doki ym. (2021)	työpaikkakysely	psykkiset oireet
Fattah ym. (2021)	työpaikkakysely	määrittelemättömät psykkiset oireet
Garcia-Herrero ym. (2017)	kansainvälinen työolo-kysely	työstressi
Hashmi (2018)	työpaikkakysely	työstressi
Havaei ym. (2021)	ammattiliittokysely	masennus- ja ahdistusoireet, traumaperäinen stressihäiriö, työuupumus
Herrero ym. (2012)	ammattiliittokysely	työstressi
Ladstätter ym. (2010)	työpaikkakysely	työuupumus
Lee ym. (2020)	työpaikkakysely	työuupumus
Lee & Shin (2010)	työpaikkakysely	työstressi
Reddy ym. (2018)	kansainvälinen työolo-kysely	työstressi
Uddin ym. (2020)	työpaikkakysely	masennusoireet
Vincent ym. (2021)	työpaikkakysely	masennusoireet
Wang ym. (2016)	sosiaalisen median julkaisut	työstressi

Taulukko 1: Koneoppimista työväestön mielenterveyden tutkimukseen hyödyntävät julkaisut, niiden aineistot sekä tutkimuskohteena oleva sairaus tai muu mielenterveyteen liittyvä vastemuuttuja.

Huolimatta kehittyvän tutkimuskentän puutteista tähän mennessä julkaistut koneoppimiseen perustuvat artikkelit osoittivat, kuinka koneoppimisen menetelmät voivat toimia varsin tehokkaana ja luotettavana välineenä mielenterveyteen voimakkaasti yhteydessä olevien tekijöiden paikantamisessa ja riskiryhmään kuuluvien henkilöiden tunnistamisessa. Tällä on merkitystä sekä tieteellisen tutkimuksen että käytännön sovellusten kannalta. Tutkijoille koneoppimisen menetelmät voivat toimia erinomaisena keinona mielenterveysongelmien taustalla olevien tekijöiden tunnistamisessa. Terveystieteiden ammattilaisten sekä työorganisaatioiden näkökulmasta menetelmät voivat johtaa automaattisten seurantavälineiden kehittämiseen ja siten entistä onnistuneempaan mielenterveyshaasteiden varhaiseen tunnistamiseen.

Kirjallisuuskatsauksemme perusteella koneoppimiseen perustuva työssä käyvien mielen terveyden tutkimus muodostaa kehittyvän tutkimusalan, jossa on paljon hyödyntämätöntä potentiaalia. Tämän potentiaalın täysimääräinen hyödyntäminen edellyttäisi kuitenkin vahvempaa yhteistyötä datatieteiden ja työterveystutkimuksen sisältöosaajien välillä. Datatieteilijöiden hallitsema kenttä hyötyisi muun muassa vuoropuhelusta sosi-aali- ja käyttäytymistieteiden sekä epidemiologisen tutkimusperinteen kanssa, sillä yhteistyön kautta olisi mahdollista hyödyntää työtä ja mielen terveyttä tutkivien tieteenalojen näkökulmia yhdessä tehokkaampien uusien digitaalisten tutkimusvälineiden kanssa. Lisäksi luonnollisen kielen prosessoinnin laajempi hyödyntäminen voisi mahdollistaa täysin uudenlaisten aineistojen käyttöönoton.

2.3 Tutkimusaineistot

2.3.1 Kysely- ja diagnoosiaineisto

Tutkimuksen ensimmäisen aineiston muodosti työterveyskysely ja siihen yhdistetty työterveyshuollon terveysrekisteriaineisto, joka kattoi kyselyä ennen ja jälkeen työterveyshuollon piiristä saadut mielen terveysongelmiin ja uniohgelmiin liittyneet lääkärin antamat diagnoosit.

Kyselyaineisto koostui Terveystalon työterveysasiakkaiden työterveyskyselyvastauksista aikaväliltä 8.8.2016–31.12.2019. Aineistoon sisällytettiin vastaamishetkellä 18–64-vuotiaat henkilöt. Kyselymuuttujia oli yhteensä 104 kappaletta. Aihealueet olivat seuraavat: Sairaudet, oireet, lääkkeiden käyttö; Näkö- ja kuulo-ongelmat; Liikunta, painonhallinta ja diabetesriski; Kipu ja fyysisen toiminnan haitta; Uni ja vireystila; Mieliala; Hyvinvointi työssä; Tupakointi ja päihteet sekä Suun terveys. Aineisto sisälsi alkuperäisessä muodossaan tiedot 107 222 kyselyvastauksesta. Kyselylomakkeen tarkempi kuvaus on liitteessä 1.

Diagnoosiaineistoon sisällytettiin ne 18–64-vuotiaat henkilöt, joille oli Terveystalon järjestelmiin kirjattu rakenteisessa muodossa mielen terveysperustainen hoitokäynti vuosilta 2012–2019. Diagnooseja oli alkuperäisessä muodossaan 157 056 kappaletta. Mielen terveysdiagnooseiksi luettiin tässä yhteydessä masennus-, ahdistuneisuus-, unihäiriö- ja työuupumusdiagnoosit (F30-F48, F51, Z73.0).

Kyselyaineistosta poistettiin vastaukset, joissa oli olennaisia puuttuvia tietoja. Tämän jälkeen kysely- ja diagnoosiaineistot yhdistettiin siten, että saman henkilön kyselyvastaukset liitettiin hänen myöhemmin mahdollisesti saamaansa mielen terveysdiagnoosiin. Henkilöt, jotka olivat aineiston perusteella saaneet diagnoosin jo ennen kyselyyn

vastaamista, poistettiin aineistosta. Samoin useammista saman henkilön kyselyvastauksista sisällytettiin vain ensimmäinen, ja mahdollisen diagnoosin jälkeiset kyselyvastaukset jätettiin huomiotta. Näin muodostetussa yhdistetyssä aineistossa mielenterveysdiagnoosi oli noin 6,6 %:lla henkilöistä.

Seuranta-ajaksi kyselyyn vastaamisesti mahdolliseen diagnoosiin määritettiin kaksi vuotta. Aineisto sisälsi myös henkilöiden työhistorian siltä osin kuin henkilö oli ollut Terveystalon työterveydenhuollon piirissä. Työhistoriaan vertaamalla aineistosta poistettiin kaikki henkilöt, jotka eivät olleet olleet kyselyn täyttämisen jälkeen joko kahta vuotta tai ennen sitä saatuun diagnoosiin asti yhtäjaksoisesti Terveystalon työterveysasiakkaina.

Yli kaksi vuotta kyselyyn vastaamisen jälkeen diagnoosin saaneet henkilöt jätettiin aineistosta pois. Vastaavasti henkilöt, jotka olivat täyttäneet kyselyn alle kaksi vuotta ennen seuranta-ajan päättymistä (31.12.2019) eivätkä olleet saaneet diagnoosia, jätettiin jatkoanalyysistä pois, koska he saattoivat saada mielenterveysdiagnoosin vielä seuranta-ajan päättymisen jälkeen.

Lisäksi vaadittiin, että aineistoon sisällytettävät henkilöt olivat kyselyn täyttäessään olleet vähintään puoli vuotta Terveystalon asiakkaina, jolloin heidän työterveyshistoriansa tunnettiin vähintään siltä ajalta.

Lopulliseen aineistoon jäi tämän suodatuksen jälkeen 13 883 henkilöä, joista 24,1 % sai seurantajakson aikana mielenterveysdiagnoosin ja 75,9 % ei saanut diagnoosia. Vaatimus kahden vuoden seuranta-ajasta nosti siis merkittävästi diagnoosin saaneiden suhteellista määrää jäljelle jääneessä aineistossa verrattuna koko aineistoon.

2.3.2 Hoitokertomustekstiaineisto

Tutkimuksen toisen pääaineiston muodosti lääkärin kirjaamat pseudonymisoidut ja suorista tunnisteista puhdistetut hoitokertomukset sekä niihin liitetyt päivämääräkohtaiset terveysrekisteritiedot keskeisistä mielenterveysdiagnooseista. Tutkimusaineistona hyödynsimme 75 331 Terveystalon rakenteisessa muodossa kirjattua hoitokertomusta aikaväliltä 1.1.2015–31.12.2019. Aineisto kattaa 21 771 potilaan hoitokertomukset, joihin liittyy masennus-, ahdistuneisuus-, unihäiriö- tai työuupumusdiagnoosi (F30–F48, F51, Z73.0).

Hoitokertomuksista tutkimuksen dokumentin muodosti yhden hoitokäynnin yhteydessä kirjatut tulosity-, esitiedot-, status- eli nykytila- ja suunnitelma-tekstiosuudet. Kertomusteksteistä oli poistettu tunnisteelliset tiedot ennen aineiston luovuttamista tutkimuskäyttöön. Hoitokertomustekstit sisältävät tietoa siitä, mitä lääkäri on

hoitoprosessissa tehnyt. Tekstit voidaan rinnastaa haastattelemalla saatuun tietoon ja koneoppimisella voidaan suorittaa analyysiä, jossa ei edetä hypoteesien avulla vaan datälähtöisesti.

Tässä tutkimuksessa hoitokertomustekstejä on käytetty kahdessa tarkoituksessa. Niiden avulla luotiin koneoppiva aihemalli, jonka perusteella voitiin tarkastella aineiston sisältöä ja rakennetta kokonaisvaltaisesti. Tämän lisäksi tekstejä käytettiin potilaiden hoitopolkujen pituutta ennustavan koneoppimismallin luomisessa.

HOITOKÄYNTIEN LUKUMÄÄRÄ

POTILAIDEN LUKUMÄÄRÄ

1	8524
2	4107
3	2576
4	1672
5	1134
6	836
7	638
8	471
9	361
10	281
11-20	985
>20	186

Taulukko 2: Kokonaisaineiston potilaiden lukumäärät jaoteltuna hoitokäyntien lukumäärän perusteella.

Aihemallinnusta varten aineistosta on käytetty hoitokertomuksia, joiden pituus oli vähintään 50 sanaa, joita oli aineistossa 50 783 kappaletta. Tällä aineistolla opetetun aihemallin avulla muodostettiin aiherepresentaatio lisäksi niille teksteille, joiden pituus oli vähintään 20 sanaa, joita oli aineistossa 69 675 kappaletta. Aineiston aihemallinnukseen perustuva eksploratiivinen tutkiminen suoritettiin käyttäen tätä aineistoa. Tässä aineistossa dokumenttien sanamäärän mediaani oli 101, keskiarvo 138 ja maksimi 1973 sanaa.

Taulukko 2 kuvaa aineiston potilaiden hoitopolkujen pituuksia esittämällä potilaiden lukumäärät hoitokäyntien lukumäärän mukaan ryhmiteltynä. Hoitopolkujen pituutta ennustavaa koneoppimismallia varten aineisto rajattiin työhistoriatietojen perusteella, jotta hoitokäyntimäärien voitiin tulkita vastaavan todellista hoitotarpeen määrää. Luokitteluun otettiin mukaan vain potilaat, joilla työsopimuksen alkupäivän ja ensimmäisen hoitokäynnin välillä oli kulunut vähintään puoli vuotta. Tällä rajauksella pyrittiin

saamaan luokitteluaineistoon mukaan vain sellaiset potilaat, joiden mielenterveyden hoitopolku alkoi tarkasteluajanjaksona eikä näin todennäköisesti ollut jatkumoa aiempaan hoitopolkuun, joka ei näkyisi aineistossa. Lisäksi vaadittiin, että potilaiden viimeinen hoitokäynti oli vähintään puoli vuotta ennen hänen työsopimuksensa loppua sekä tarkastelujakson loppua eli vuoden 2019 loppua. Tällä rajauksella haluttiin varmistaa, että aineistossa näkyvä hoitopolun loppu sekä polun pituus vastaisivat todellista hoitopolun loppua ja pituutta. Näiden rajausten seurauksena luokitteluaineistoon jäi 14 653 potilasta. Luokitteluaineiston taustatietoja on esitettyä taulukossa 3.

HOITOPOLKU

	Lyhyt	Pitkä
HENKILÖITÄ	9792	4861
KESKI-ikä	46,2 v	44,8 v
NAISTEN OSUUS	62,20 %	67,20 %
DIAGNOOSIEN MÄÄRÄ F32	1502	1638
DIAGNOOSIEN MÄÄRÄ F33	352	548
DIAGNOOSIEN MÄÄRÄ F41	2142	1608
DIAGNOOSIEN MÄÄRÄ F43	3149	1283
DIAGNOOSIEN MÄÄRÄ F51	4189	1684
DIAGNOOSIEN MÄÄRÄ Z73.0	625	412
DIAGNOOSIEN MÄÄRÄ MUUT	398	221
HENKILÖITÄ	9792	4861
KESKI-ikä	46,2 v	44,8 v

Taulukko 3: Hoitopolun pituuden ennustemalliin käytetyn aineiston tilastot jaettuna hoitopolun pituuden luokkiin. Lyhytpolkuisilla potilailla on aineistossa vähemmän kuin viisi ja pitkäpolkuisilla vähintään viisi hoitokäyntiä. Diagnoosien lukumäärät on laskettu kahden ensimmäisen hoitokäynnin perusteella.

2.4 Tutkimusasetelma ja menetelmät

2.4.1 Tutkimusasetelma

Hankkeen analyysit perustuivat kahteen erilliseen tutkimusasetelmaan, joissa käytetty aineisto sekä menetelmät olivat osittain samoja. Molemmat asetelmat olivat luonteeltaan pitkittäistutkimukseen perustuvia, joissa käytettiin tietoja useasta aikapisteestä. Asetelmassa kerättiin tietoa lähtötason mielenterveydestä ja ennakoitiin tulevaa mielenterveyden tilaa.

Ensimmäistä asetelmaa käytettiin vastaamaan ensimmäiseen tutkimuskysymykseemme koskien mielenterveysongelmia ja uiongelmiä ennustavia tekijöitä suomalaisessa

työssä käyvässä väestössä. Tutkittavien ryhmään valittiin ne työntekijät, jotka olivat vastanneet työterveyshuollon teettämään työterveyskyselyyn. Työterveyskysely toimi laajaa ennustavaa materiaalia koneoppimisen mallille tarjoavana muuttujakokonaisuutena. Tutkimuksen tässä asetelmassa työterveyskyselyn yli 100 muuttujan avulla pyrittiin ennakoidaan lääkärin määrittämää lähitulevaisuudessa ilmenevää mielenterveysdiagnoosia ja paikantamaan kaikkein olennaisimmat sitä ennustavat tekijät.

Analyysien edetessä tuotimme mallin, joka ennustaa vastaajan iän, sukupuolen sekä työterveyshuollon teettämän työterveyskyselyn vastausten perusteella yksilön saamaa ensimmäistä mielenterveysdiagnoosia kahden vuoden kuluessa kyselyyn vastaamisesta. Malli perustui ennustavaan luokittelumallinnukseen.

Toinen tutkimusasetelma vastasi toiseen tutkimuskysymykseemme koskien mielenterveyteen ja uniongelmiin liittyvän hoitoketjun pitkittymistä ennustavista tekijöistä suomalaisessa työssä käyvässä väestössä. Tässä asetelmassa huomio puolestaan kohdistui mielenterveysdiagnoosin saaneiden henkilöiden mielenterveysdiagnoosien uusiutumiseen ja pitkittymiseen. Tutkimusjoukkoon sisällytettiin vain ne työterveyshuollon asiakkaat, joilla oli vähintään yksi mielenterveysdiagnoosi seurannan alussa.

Tässä tutkimusasetelmassa tuotimme mallin, joka ennustaa hoidon pitkittymistä työterveyshuollossa yli neljän hoitokäynnin mittaiseksi. Lääkärikäynteihin liittyvien tekstien lisäksi hyödynsimme analyyseissa tietoja iästä, sukupuolesta ja diagnoosista. Keskeisin mielenkiintomme kohde oli se, voidaanko hoitopolulla alkupään kertomustekstien tietosisällöllä ennustaa tulevaa käyntien määrää. Tekstien analysoinnissa käytettiin luonnollisen kielen prosessointiin kehitettyä koneoppimismenetelmää nimeltä aihemallinnus. Ennustamisessa käytettiin puolestaan samanlaista luokittelumallinnusta kuin ensimmäisessäkin tutkimusasetelmassa.

Kumpakin tutkimusasetelmaa käytettiin vastaamaan kolmanteen tutkimuskysymykseemme, joka koski ennusteiden tarkkuutta mielenterveysdiagnoosin ilmaantumisen sekä hoidon pitkittymisen ennustamisessa koneoppimisen menetelmiä hyödyntäen. Ennustemallinnusten luokittelukyvyn arviointiin hyödynnettiin molemmissa asetelmissa samaa välinettä, joka kertoo mielekkäällä tavalla luokittelijan kyvystä sekä tunnistaa todelliset positiiviset tapaukset (esim. diagnoosin saavat henkilöt) että todelliset negatiiviset tapaukset (esim. ilman diagnoosia jäävät henkilöt). Analyysimenetelmät ja tulosten evaluointimenetelmät ovat kuvattu tarkemmin seuraavissa alaluvuissa.

2.4.2 Kyselyaineistoon perustuvat analyysit

Ensimmäistä mielenterveysdiagnoosia ennustettiin yhdistettyyn kysely- ja mielen-terveysdiagnoosiaineistoon perustuen XGBoost (eXtreme Gradient Boosting) -luokittelumenetelmällä (Chen & He 2014, Chen & Guestrin 2016). Menetelmä perustuu usean yksinkertaisen päätöspuuluokittelumallin yhdistämiseen (boosting) siten, että seuraavat päätöspuut ennustavat aina edellisten puiden jättämää mallinnusvirhettä. Puiden lisäämisessä hyödynnetään tavoitefunktion gradienttia, jonka suuntaan etenemällä mallinnusvirhettä minimoidaan. Mallin lopullinen ennustearvo saadaan kaikkien mallin puiden antamien ennusteiden painotettuna summana. XGBoost-algoritmi erityisen hyvin nopeuden ja suorituskyvyn suhteen optimoitu gradient boosting -pätöspuualgoritmi, ja on siksi hyvin suosittu koneoppimismenetelmä niin luokittelu- kuin regressio-ongelmienkin ratkaisemisessa.

2.4.3 Hoitokertomusteksteihin perustuvat analyysit

Hoitokertomustekstejä analysoitiin koneoppimismalleilla kahdella eri tasolla. Ensimmäiseksi tekstidata muutettiin analyyseja varten numeeriseen muotoon, mikä tässä hankkeessa tehtiin käyttäen aihemallinnusta. Toisella tasolla aihemallinnuksen teksteille tuottamia representaatioita hyväksi käyttämällä opetettiin koneoppiva luokittelumalli ennustamaan potilaiden hoitopolun pituutta. Mallinnusten tuloksista kerrotaan luvussa 3.2.

Aiheiden tunnistaminen teksteistä on ihmis- ja yhteiskuntatieteissä toistaiseksi vähän käytetty tapa muodostaa tietoa ja siksi on paikallaan kertoa tarkemmin aihemallinnuksen prosessista. Aihemallinnuksen idea on lähtöisin tiedonhaun tutkimuksesta, mutta sitä voi soveltaa monella eri tavalla. Sen päätavoitteena on muuntaa tekstidokumenttikokoelman sanastopohjainen esitys piilevien muuttujien eli aiheiden avulla tyypistettyyn muotoon, jolloin representaation dimensionaalisuus pienenee sanaston koosta (usein kymmeniä tuhansia sanoja) aiheiden lukumäärään (usein kymmeniä tai satoja). Tämän seurauksena voidaan saada kokonaisvaltainen kuva dokumenttikokoelman sisällöstä ja rakenteesta sekä mitata dokumenttien välisiä sekä sanojen välisiä semanttisia samankaltaisuuksia. Tässä hankkeessa käytimme aihemallinnusta ensimmäisellä tasolla aineiston tarkastelua ja hahmottamista varten sekä toisella tasolla hoitopolkujen pituutta ennustavan mallin selittävinä muuttujina.

Aihemallinnusvaihe suoritettiin käyttämällä latent Dirichlet allocation -menetelmää (LDA; Blei ym. 2003, Blei 2012, Beaulieu-Jones ym., 2019). LDA on ohjaamaton generatiivinen bayesiläinen koneoppimismalli, jossa lähtöoletuksena on, että suuressa tekstidokumenttikokoelmassa jokainen yksittäinen dokumentti perustuu muutama

semanttiseen *aiheeseen*. Aihe määritellään todennäköisyysjakaumaksi kokoelman sanaston yli, ja aiheiden kokonaislukumäärä aineistossa on käyttäjän päätettävissä. Yhdessä aiheessa voi esimerkiksi esiintyä todennäköisimpinä sanoina sanat "annos", "milligramma" ja "käyttää", viitaten lääkitykseen liittyvään aiheeseen, kun taas toisessa aiheessa todennäköisimpiä sanoja voivat olla "väsynyt", "heräillä" ja "yö", jonka voi tulkita uni- tai unettomuus-aiheeksi.

LDA:n oletusten mukaan jokaisen tekstidokumentin sanat valikoituivat dokumenttiin sen aiheiden perusteella. Aiheet siis tuottivat dokumentissa esiintyvät sanat. LDA on niin sanottu "bag-of-words" -malli. Se tarkoittaa sitä, että malli ei ota huomioon sanajärjestystä dokumentin sisällä, vaan ainoastaan sen, mitkä sanat dokumentissa esiintyy sekä sanojen esiintymismäärät.

Näiden oletusten perusteella LDA käy läpi dokumenttikokoelman ja oppii tunnistamaan, mitkä sanat esiintyvät usein samoissa dokumenteissa ja kuuluvat siis samaan aiheeseen. Tämän oppimisen lopputuloksena LDA tuottaa dokumenttikokoelmaan sopivat aiheet sekä päättelee jokaisen dokumentin kohdalla, mitkä aiheet ovat generoineet kyseisen dokumentin.

LDA:ta varten tekstejä esikäsiteltiin usealla eri tavalla. LDA:n suorittaman sanojen yhdistelemisen kannalta yksi haaste on dokumenttikokoelman sanaston koko, koska mitä suurempi sanasto on, sitä harvinaisempia sanojen yhteisesiintymät ovat. Hankkeen hoitokertomustekstiaineisto on tässä mielessä ongelmallinen muutamastakin syystä.

Ensinnäkin hoitohenkilökunta joutuu tekemään kirjauksensa nopeasti, minkä seurauksena teksteissä esiintyy verrattain paljon kirjoitusvirheitä sekä lyhenteitä – niin lääketieteellisiä (esim. "l.a." = laterum amborum, molemmipuolinen) kuin konventionaalisia (esim. "pt", "pot" tai "plas" = potilas). Kirjoitusvirheiden suhteen aineistolle ei tehty esikäsitelyä, koska kirjoitusvirheissä on vaikea havaita säännönmukaisuuksia, vaikkakin työkaluja myös tähän ongelmaan on olemassa. Sen sijaan aineistosta tunnistettiin useimmin esiintyviä lyhenteitä ja muokattiin tekstiä niiden osalta korvaamalla lyhenne auki kirjoitetulla vastineellaan (esim. "pt" → "potilas"), yrittäen myös säilyttää lyhenteeseen mahdollisesti liittyvä taivutusmuoto (esim. "pot:lla" → "potilaalla"). Lyhenteiden avaamisen vaikutusta ei erikseen arvioitu, mutta se oli perusteltua varsinkin potilas-esimerkkisanan kohdalla, joka eri muodoissaan on yksi aineiston yleisimmistä sanoista.

Toiseksi suomenkielinen teksti sisältää verrattain paljon saman sanan eri taivutusmuotoja, jotka kone naiivisti tulkitsee eri sanoiksi. Tällöin eri sanamuotoja kertyy sanastoon huomattavasti enemmän kuin useissa muissa kielissä vastaavalla käännostekstillä. Tätä ongelmaa helpotettiin perusmuotoistamalla sanat neuroverkkokielimalleihin

perustuvalla Turku neural parser -työkalulla (Kanerva ym., 2018), joka mm. tunnistaa suomenkielisen tekstin sanojen sanaluokkia ja taivutusmuotoja tuottaen samalla sanojen perusmuodon.

Lyhenteiden avauksen ja sanojen perusmuotoistamisen välissä tekstistä tunnistettiin *n-grammeja* eli sanayhdistelmiä tai fraaseja, jotka esiintyvät aineistossa usein. Sopivat *n-gramit* voivat heijastaa syvempää semanttista sisältöä kuin yksittäiset sanat. Lisäksi *n-gramien* yhteen liittäminen lieventää LDA:n bag-of-words-oletusta, sillä sen avulla sanajärjestys voidaan osittain säilyttää. *N-grammeja* käytettiin esimerkiksi negatioiden tunnistamiseen poimimalla aineistosta yleisimmät 2–5 sanan pituiset sanajonot, joissa esiintyy sana "ei". Näistä "ei"-*n-grammeista* poimittiin manuaalisesti semanttisesti merkittävät fraasit, ja niiden sanat yhdistettiin alaviivalla. Esimerkiksi fraasi "ei ole työkykyinen" muunnettiin *n-gramiksi* – käytännössä siis uudeksi sanaksi – "ei_ole_työkykyinen". Tämän tavoitteena oli vähentää assosiaatiota työkykyisten ja työkyvyttömiä potilaiden kertomustekstien välillä ja mahdollisesti tunnistaa nämä erillisiksi aiheiksi.

Toinen *n-gramien* määrittely tehtiin lainausten avulla. Aineistossa esiintyy usein lääkärin kirjoittamia suoria lainauksia potilaan puheesta. Aineistosta poimittiin kaikki alle 100 merkin pituiset sanajonot, jotka esiintyvät lainausmerkkien sisällä. Tämän jälkeen aineistosta tunnistettiin näitä lainauksia vastaavat sanajonot (ilman lainausmerkkejä) ja niiden lukumäärät laskettiin. Näistä sanajonoista ne, jotka esiintyivät aineistossa vähintään viisi kertaa, määriteltiin sanastoon *n-grammeiksi*, ja ne yhdistettiin alaviivoilla, kuten yllä negatioiden kohdalla.

Viimeisenä esikäsittelyvaiheena ennen LDA-analyysiä tekstiaineistosta poistettiin niin sanotut stopwordit eli yleisimmät suomen kielen sanat, joilla ei ole vahvaa semanttista merkitystä ja jotka samalla aiheuttavat tekstidokumenttien välille "liikaa" yhteyksiä LDA:n tulkittavaksi. Esikäsittelyjen jälkeen teksteistä poistettiin välimerkit ja jokainen dokumentti hajotettiin järjestämättömäksi sanalistaksi välilyöntien kohdalta. Näin aineistosta muodostunut dokumenttien eli sanalistojen joukko annettiin syötteenä LDA:lle.

Tiivistäen vielä todetaan, että yksittäisessä dokumentissa aiheet muodostavat todennäköisyysjakauman, joka summautuu ykköseen. Aiheen sisältämät sanat muodostavat myös todennäköisyysjakauman, joka summautuu ykköseen. Suurimman todennäköisyyden sanat ovat aiheen avainsanoja. Avainsanojen avulla voidaan laatia kuvailevat lauseet kertomaan aiheen sisällöstä kuten tekemisestä, kohteesta ja toimijoista. Esimerkiksi yhdessä hoitokertomukseen liittyvässä aiheessa voidaan pohtia asiakkaan/potilaan tilannetta tai suunnitella hoitoa. Samat avainsanat voivat sisältyä useampaan eri

aiheeseen, jolloin niiden merkitys kussakin aiheessa riippuu niiden suhteesta aiheen muihin sanoihin.

Aihemallinnus voidaan tehdä erilaisilla aiheiden lukumäärillä (esimerkiksi 5–200). Tutkija valitsee sen, millainen aiheiden määrä on riittävä. Tässä tutkimuksessa käytettiin 160 aiheen ratkaisua. Tähän valintaan vaikutti se, että hoidon pitkittymistä ennustavassa tutkimusasetelmassa (luku 3.2.3) 160 aiheen ratkaisu tuotti parhaimman tuloksen, eli ennusti voimakkaimmin mielenterveyteen ja uniongelmiin liittyvien hoitokäyntien pitkittymistä. Näistä aiheista 20 aihetta arvioitiin keskeisiksi ja ne voitiin ryhmitellä neljään kokonaisuuteen:

- Mielenterveyden oireet, hoito ja arviointi
 - a. Masennus
 - b. Ahdistus
 - c. Uupumus
 - d. Uni
 - e. Tutkimus
- Toimenpiteet
 - a. Lääkitys
 - b. Terapia
- Työ
- Perhe

Aiheet eivät olleet avainsanojen osalta täysin toisensa poissulkevia, vaan useampaan aiheeseen liittyivät esimerkiksi sekä sairauslomaan että työterveyspsykologisiin viittaavat avainsanat.

Aihemallinnuksen tuottamia aiheita käytettiin myös potilaiden hoitopolkujen pituutta ennustavan koneoppimismallin selittävinä muuttujina. Hoitopolun pituuden ennustaminen yksinkertaistettiin binaariseksi luokitteluongelmaksi jakamalla aineiston potilaat kahteen luokkaan heidän aineistostansa laskettujen hoitokäyntilukumääriensä perusteella. Lyhythoitoisten luokkaan valittiin potilaat, joilla oli vähemmän kuin viisi hoitokäyntiä ja pitkähoitoisten luokkaan potilaat, joilla oli viisi tai enemmän hoitokäyntiä. Luokittelua varten rajattu aineisto kuvattiin luvussa 2.3.2.

Luokittelun selittäviksi muuttujiksi otettiin 160 aiheen LDA-mallin tuottama aihejakauma potilaan kahden ensimmäisen hoitokäynnin kertomusteksteille. Toisin sanoen jokaista aineiston potilasta kuvasi 160-uloitteinen vektori/todennäköisyysjakauma/lukujono, jonka LDA-malli tuotti kahdelta ensimmäiseltä hoitokäynniltä yhdistettyyn kertomustekstiin. Näiden 160 muuttujan lisäksi selittävinä muuttujina käytettiin potilaan sukupuolta ja ikää sekä tietoa siitä, mitä mielenterveysdiagnooseja potilaalle oli määritelty kahdella ensimmäisellä hoitokäynnillä.

Luokittelijamallina käytettiin XGBoost-luokittelijaa, joka on kuvattu tarkemmin luvussa 2.4.2. Luokittelija opetettiin käyttämällä 80 prosenttia luokiteltavista potilaista opetusaineistona. Mallille siis syötettiin näiden potilaiden selittävien muuttujien arvot sekä luokatieta (lyhyt/pitkä), minkä perusteella malli oppi tunnistamaan vastaavuuksia muuttuja-arvojen ja luokkien välillä. Tämän jälkeen mallin suorituskykyä arvioitiin käyttämällä testiaineistona loppuja 20 prosenttia potilaista. Opetetulle mallille syötettiin nyt vain potilaiden selittävien muuttujien arvot, joiden perusteella malli tuotti ennusteen potilaiden luokille. XGBoost-malli tuottaa kullekin potilaalle pistearvon nollan ja yhden väliltä, jonka voi tulkita todennäköisyydeksi sille, että potilas kuuluu pitkähoitoisten potilaiden luokkaan. Näitä todennäköisyysarvoja käytettiin mallin suorituskyvyn mittaamiseen ROC-käyrän alle jäävän pinta-alan avulla, josta tarkemmin luvussa 2.4.4.

2.4.4 Tulosten arviointi

Mielenterveysdiagnoosien mallinnuksessa mallin luokittelutuloksien evaluointiin hyödynnettiin ROC-käyrää (Receiver Operating Characteristic) ja sen alle jäävää pinta-alaa (Area Under Curve, AUC) (Forsström 1995, Fawcett 2006). Tulosten merkitsevyyden tarkasteluun käytettiin lisäksi AUC-pinta-alan keskivirhettä ja luottamusväliä, jotka laskettiin ei-parametrisella menetelmällä (Delong ym. 1998).

ROC-käyrä muodostetaan koordinaatistoon, jossa vaaka-akselilla on luokittelumallin väärin positiivisten osuus (1-spesifisyys) ja pystyakselilla oikeiden positiivisten osuus (herkkyys). Mallin väärin ja oikeiden positiivisten osuudet riippuvat kynnsarvosta, ja ROC-käyrä muodostuu, kun osuudet piirretään koordinaatistoon kaikilla mahdollisilla kynnsarvoilla (0...1). Mitä enemmän käyrän alle jää pinta-alaa, sen parempi luokittelijan suorituskyky on. Tyypillisenä vertailukohtana mallin suorituskyvylle käytetään satunnaislukittelijaa, jonka ROC-käyrä on suora (väärin positiivisten osuus = oikeiden positiivisten osuus) ja AUC-arvo 0,5.

Myös hoitokertomusteksteihin perustuvan ennustemallin suorituskyvyn mittarina hyödynnettiin ROC-käyrää. Luokittelumalli tuottaa jokaisen potilaan kohdalla todennäköisyyden sille, että potilas kuuluu pitkäkestoisimpien hoidettavien ryhmään. ROC-käyrä ja

sen rajaama pinta-ala (AUC) mittavat näiden todennäköisyyksien ja todellisen luokituk-
sen vastaavuutta. Tämän ennustemallin yhteydessä ROC-käyrän pinta-ala vastaa sen
todennäköisyyttä, että yksi satunnaisesti poimittu lyhytaikainen potilas saa luokittelussa
matalamman todennäköisyysarvon kuin satunnaisesti valittu pitkäaikainen potilas.

2.5 Tutkimuseettiset näkökohdat

Tutkimuksessa hyödynnetty aineisto kuuluu sosiaali- ja terveystietojen toissijaista käyt-
töä koskevan lain (552/2019) piiriin. Tutkimusluvan hankkeelle myönsi sosiaali- ja ter-
veysalan tietolupaviranomainen Findata (päätös Dnro THL/1935/14.02.00/2020). Aineis-
ton käsittelyssä hyödynnettiin vahvoja tietoturvakäytäntöjä sekä Tutkimuseettisen neu-
vottelukunnan (TENK) ohjeita hyvästä tieteellisestä käytännöstä.

Hankkeessa ei kontaktoitu tutkittavia eikä kerätty heiltä suoraan tietoa. Tutkimus on ta-
pahtunut toisiokäyttölain mahdollistamalla tavalla hyödyntäen aineistontarjoajan omiin
rekistereihinsä valmiiksi keräämää tietoa. Aiemmin hyödyntämättömästä tekstimuotoi-
sesta aineistosta sekä uudenlaisista koneoppimisen menetelmistä huolimatta hanke
noudattaa periaatteiltaan jo vuosikymmeniä jatkuneen rekisteritutkimuksen periaat-
teita. Hankkeen aiheuttamat haitat tutkittaville on pyritty estämään varmistamalla tieto-
suojan säilyminen pitävästi hankkeen kaikissa vaiheissa. Hankkeen myötä ei ole muo-
dostunut uutta henkilörekisteriä eikä hankkeeseen ole liittynyt yksilöä koskevaa päätök-
sentekoa.

Tutkimusaineistoa ei missään vaiheessa siirretty tai luovutettu aineistontarjoajan (Ter-
veystalo) tietoteknisestä ympäristöstä. Tässä ympäristössä aineistoa suojaavat Terveys-
talon valvontajärjestelmät. Aineistoon oli pääsy ainoastaan ennalta nimetyillä tutkijoilla,
jotka allekirjoittivat sekä Findatan että Terveystalon salassapitositoumuksen.

Rakenteellisessa muodossa oleva aineisto pseudonymisoitiin ja tekstiaineistoista pois-
tettiin suorat tunnisteet Terveystalon toimesta. Terveystalon tietosuojavastaava kävi läpi
ja arvioi huolellisesti näiden toimenpiteiden onnistumisen ennen aineiston luovutta-
mista tutkimuskäyttöön. Aineistoa analysoitiin siten, että yksittäisiä henkilöitä tai orga-
nisaatioita ei ollut mahdollista edes epäsuorasti tunnistaa mistään Työterveyslaitokselle
siirrettävästä tulosmateriaalista.

Näiden toimenpiteiden myötä tietosuojan vaarantumisen tai muun tutkittaville koitu-
van haitan riski on arvioitavissa erittäin pieneksi. Lisäksi on huomattava, että hankkeen
toteutus perustuu koneelliseen tietojen louhintaan ja tuhansien henkilöiden materiaalin
hyödyntämiseen, eikä yksittäisten henkilöiden tiedot ole voineet millään tasolla tulla
analyysin tai raportoinnin kohteiksi. Hankkeen tulokset on julkaistu avoimesti ja ne ovat

saatettu julkisesti saataville muun muassa tiedejulkaisujen ja Työelämä-tieto-palvelun kautta. Täten hankkeen tulosten avulla on pyritty tuottamaan mahdollisimman laajavai-
kutteisia yhteiskunnallisia ja yksilön hyvinvointia koskevia hyötyjä.

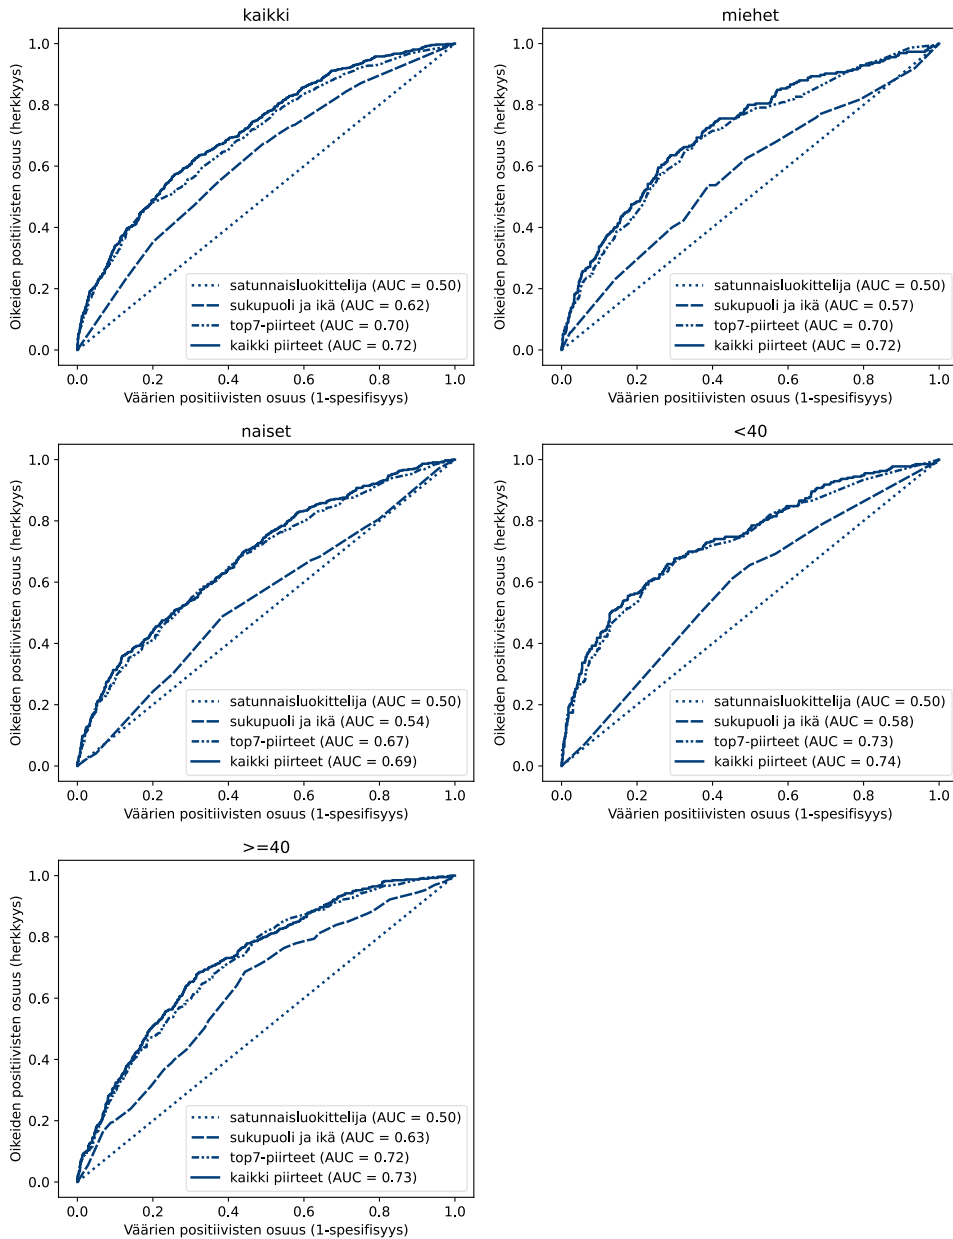
3 Päätulokset

3.1 Mielenveysdiagnoosin ennustaminen terveystarkkelyyn perustuen

Ensimmäisen mielenveysdiagnoosin ennustemalli laskettiin aluksi hyödyntäen kaikkia työterveyskyselyn 104 vastausmuuttujaa, eli kaikkia käytettävissä olevia datan piirteitä. Tällä mallilla on lähtökohtaisesti paras ennustetarkkuus, koska kaikki kyselystä saatava informaatio on sen käytettävissä. Koska mallista tulee kuitenkin melko monimutkainen ja on syytä olettaa, etteivät kaikki yleisluontoisen työterveyskyselyn kysymykset voi olla merkittäviä mielenveysdiagnoosin kannalta, tarkasteltiin myös yksinkertaisempaa eli seitsemään tärkeimpään kysymykseen perustuvaa mallia. XGBoost-malli pystyy itse arvioimaan käyttämiensä piirteiden (tässä siis kyselyvastausten) merkitystä, ja tätä ominaisuutta hyödynnettiin top7-mallin piirteiden valinnassa. Malleja verrattiin triviaalimalliin, jossa käytössä oli vain henkilön sukupuoli ja ikä, sekä satunnaisluokittelijaan, joka ennustaa diagnoosin saamisen piirteistä riippumatta täysin sattumanvaraisesti.

3.1.1 Mallien suorituskyky

Kuva 1 esittää mallien ROC-käyrät koko datalle sekä eri alaryhmille. Sukupuoleen ja ikään perustuva triviaalimalli pystyi kaikissa tapauksissa joko hieman tai selvästi parempaan luokitteluun kuin satunnaisluokittelija. Sekä täyden piirrejoukon että seitsemän tärkeimmän piirteiden mallit luokittelevat kuitenkin aineiston vielä selvästi paremmin, eli terveystarkkelyyn vastauksilla on lisäennustearvoa mielenveysdiagnoosien suhteen. Kuvasta nähdään toisaalta myös hyvin, että piirteiden määrän tiputtaminen täydestä (104 kpl) seitsemään ei merkittävästi heikentänyt luokittelutuloksia. Tämä tukee sitä oletusta, että vain pieni osa kyselyn kysymyksistä sisältää merkittävästi mielenveysdiagnoosiennustetta parantavaa tietoa.



Kuva 1. Mielenterveysdiagnoosin ennustusmallien ROC-käyrät koko datalle sekä alaryhmillä (miehet, naiset, alle 40-vuotiaat ja 40-vuotiaat tai vanhemmat).

PIIRRE- JOUKKO	ALARYHMÄ	AUC	SE	95 %:N LUOTTAMUSVÄLI	P-ARVO
SUKUPUOLI JA IKÄ	kaikki	0,62	0,012	0,59 - 0,64	<0,001
	miehet	0,57	0,022	0,53 - 0,62	<0,001
	naiset	0,54	0,016	0,51 - 0,57	0,164
	alle 40v	0,58	0,020	0,54 - 0,62	0,017
	40v ja yli	0,63	0,016	0,60 - 0,66	<0,001
TOP7-PIIR- TEET	kaikki	0,70	0,012	0,67 - 0,72	<0,001
	miehet	0,70	0,019	0,66 - 0,74	<0,001
	naiset	0,67	0,015	0,64 - 0,70	<0,001
	alle 40v	0,73	0,019	0,69 - 0,77	<0,001
	40v ja yli	0,72	0,014	0,69 - 0,74	<0,001
KAIKKI PIIR- TEET	kaikki	0,72	0,011	0,69 - 0,74	<0,001
	miehet	0,72	0,019	0,68 - 0,75	<0,001
	naiset	0,69	0,015	0,66 - 0,71	<0,001
	alle 40v	0,74	0,018	0,71 - 0,78	<0,001
	40v ja yli	0,73	0,014	0,70 - 0,76	<0,001

Taulukko 4. Mielenterveysdiagnoosia ennustavien mallien tunnusluvut eri piirrejoukoilla ja alaryhmissä. Nollahypoteesina on käytetty satunnaisluokittelijaa, jonka AUC-arvo on 0,5.


Taulukko 4 kuvaa tarkemmin eri luokittelutapausten tulokset. Parhaat luokittelutulokset AUC-pinta-alalla mitattuna saadaan kaikkien piirteiden ja top7-piirteiden malleille alle 40-vuotiaiden ikäryhmässä. Kuitenkin kaikki alaryhmät näillä varsinaisilla malleilla saadaan ennustettua selvästi paremmin kuin triviaalimallilla tai satunnaisluokittelijalla (nollahypoteesi). Pelkän sukupuoli- ja ikätiedon perusteella ennustava triviaalimalli ei naisten osalta ole tilastollisesti merkittävästi parempi kuin satunnaisluokittelija 95 %:n luottamusväliillä. Muuten kaikki mallit ovat myös tilastollisesti satunnaisluokittelijaa parempia.

3.1.2 Vastausmuuttujien merkitsevyys ennusteen kannalta


Merkittävin yksittäinen kyselyvastaus eli piirre mielenterveysdiagnoosin ennusteen kannalta oli vastaajan itsearvioitu stressin tunne (kuva 2). Koko otoksessa seuraavaksi tärkeimmiksi piirteiksi nousivat väsymys ja uupumus päiväsaikaan sekä surumielisyyys ja alakuloisuus. Myös ahdistusoireet ja naissukupuoli lisäsivät mielenterveyteen ja unihäiriöihin liittyvien diagnoosien todennäköisyyttä.

Alaryhmien osalta muista näyttäisi poikkeavan ainakin alle 40-vuotiaiden ryhmä, jossa päiväaikainen väsymys ja uupumus eivät muiden ryhmien tapaan ole merkittäviä

selittäjiä. Sen sijaan mielialaan liittyvien kysymysten merkitys korostuu tässä ryhmässä stressin lisäksi. Miesten alaryhmässä arvottomuuden tunteminen nousee seitsemän tärkeimmän piirteen joukkoon, vaikka se ei esiinny 20 tärkeimmän piirteen joukossa koko aineistolle.



a)



b)

Kuva 2. Ennustusmallien tärkeimmät piirteet, jotka selittävät mielenterveysdiagnoosin saamista sekä niiden suhteellinen tärkeys. a) kaikkien piirteiden koko datan mallin 20 tärkeintä piirrettä, b) top7-mallien kaikki piirteet.

3.2 Hoitokertomustekstien aihemallinnus

Seuraava raportin osuus hyödyntää työterveyshuollossa toimivien lääkäreiden kirjaamia hoitokertomustekstejä koneoppimisen aineistona, joilla mielenterveyshoidon pitkittymistä ennakoidaan hyvin suuressa joukossa työntekijöitä. Tutkittavalla joukolla on lähtökohtaisesti jokin mielenterveyden tapahtuma lähtötilassa, mutta ei muuta lääkärin lähiaikoina kirjaamaa mielenterveyteen tai uniongelmiin liittyvää hoitotapahtumaa työterveyshuollon piiristä.

Hoitokertomuksista tunnistetut teemat on tässä ymmärretty aiheiksi, joilla työntekijöiden mielenterveyden hoitotarpeisiin on pyritty vastaamaan tai ylipäätään reagoimaan. Aiheita tarkastellaan tavoitteellisen työkykyä ennakoivasti tukevan ja ylläpitävän toiminnan näkökulmasta. Ensiksi esitetään tulosten visualisointi vakiintuneen käytännön avulla (Sievert & Shirley, 2014) ja tulkitaan aiheiden sisällöt. Toiseksi tarkastellaan joidenkin aiheiden trendien kehittymistä neljän vuoden tutkimusjaksolla viikkorytmien avulla. Kolmanneksi kerrotaan, miten aiheita hyödynnettiin hoidon pitkittymisen ennustajina. Neljänneksi arvioidaan aihemallinnuksella saadun tiedon luotettavuutta.

3.2.1 Työterveyshuollon mielenterveyden tukeen liittyvät aiheet

Aihemallinnuksen tulosesittelyyn on vakiintunut visualisointityökalu (Sievert & Shirley, 2014), jonka avulla tuloksia esitellään myös tässä raportissa. Kuvassa 3 esitellään yksi työhön liittyvä aihe esimerkkinä visualisoinnista.


Kuvassa vasemmalla on 160 aihetta palloina, joista mielenterveyden kannalta keskeisimmät aiheet sijoittuvat alareunaan. Oikealla on 30 avainsanaa, jotka on todennäköisyyksiensä perusteella listattu siten, että suurinta todennäköisyyttä kuvaa on punainen palkki, joka on sijoitettu kuviossa ylimmäiseksi. Sininen palkki kertoo avainsanan yleisyydestä koko aineistossa aiheesta riippumatta.

Avainsanan punaisen palkin suhde siniseen palkkiin kertoo, miten paljon kyseinen avainsana esiintyy/latautuu vain tässä aiheessa. Jos punainen palkki on vähintään puolenvälin yli sinistä palkkia, niin avainsana kertoo erityisesti tästä aiheesta. Esimerkiksi aiheen 49 avainsanoissa kuvassa 3 on paljon sellaisia sanoja, jotka latautuvat vain tälle aiheelle (turkoosi nuoli kuvassa kuvaa näitä aiheita). Aihe voidaan tulkita käyttämällä turkoosin nuolen mukaisia avainsanoja ja ottamalla myös ylin avainsana huomioon.


Selected Topic:

Slide to adjust relevance metric:⁽²⁾ $\lambda = 1$

Intertopic Distance Map (via multidimensional scaling)



Top-30 Most Relevant Terms for Topic 49 (3.3% of tokens)



1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))]; for topics t, see Chuang et. al (2012)
2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Kuva 3. Työhön liittyvän aiheen numero 49 visualisointi, jossa pallot ja palkit ovat aihehallinnuksen visualisointivälineen tuottamia ja turkoosit nuolet ovat tutkijan kuvaan erikseen tekemiä.

Tulkintaan on otettu mukaan vielä usein eri aiheissa toistuvat työterveyspsykologi/psykologi ja sairausloma/sairasloma/sairasvapaa avainsanat sekä lääkitys. Esimerkiksi oikein kuvan aiheen 49 tulkinta on:

- **Työyhteisöön kohdistuvat toiminta** sisältäen mm. työyhteisön, tiimin, palaverin, työkaverin, työntekijän, esimiehen ja työterveyspsykologin.

Työterveyshuollon mielenterveyden 20 aihetta ovat esitetty taulukossa 5. Aiheiden visualisoinnit avainsanalistaustukseen puolestaan ovat esitetty liitteessä 2.

Keskeisten aiheiden esiintymisen intensiteettiä kuvaillaan käyntikertojen eli hoitopolkujen mukaisissa osaryhmissä: kerran lääkärillä käyneet, 2–3 kertaa käyneet ja yli kolme kertaa käyneet. Intensiteetti on saatu laskemalla dokumenttien aiheen todennäköisyydet yhteen osaryhmittäin.

Aiheen intensiteetti tulkitaan tässä seuraavasti. Kun lukema on korkea, aihetta käsitellään usein työterveyshuollossa ja lukeman ollessa alhainen aihetta käsitellään harvoin.

Aihe nro	AVAINSANOJEN AVULLA LAADITUT TULKINNAT AIHEISTA	LÄÄKÄRILLÄ KÄYNTIEN MÄÄRÄ			Yhteensä
		1	2–3	>=4	
MIELENTERVEYDEN OIREET, HOITO JA ARVIOINTI					
155	Toistuva keskivaikea masennus sisältäen mm. psykiatrin konsultaatio sekä lääkitys, sairausloma ja työterveyspsykologi,	1,1	1,4	2,0	4,5
48	Tutkimus , sisältäen mm. somaattinen, kognitiivinen	0,8	0,8	1,1	2,7
40	Jo pitkään uupumus sisältäen mm. uupuminen, alavireisyys sekä lääkitys ja sairausloma	1,8	2	1,9	3,9
5	Jatketaan sairauslomaa sisältäen mm. väsyneen oloinen, uupua, uupunut, enää/ei enää (pysty, jaksaa)	1,0	1,1	1,2	3,3
123	Ahdistus sisältäen mm. itkuinen, eilen, tänään, ahdistua, tilanne sekä sairausvapaa ja psykologi	5,4	4,8	3,5	13,7
125	Ahdistusoireilu sisältäen mm. ahdistusoire, stressioire, jaksamattomuus, voimistua, vaihtelevasti, masennus ja lääkitystä (milligramma),	0,4	0,8	0,9	2,1
126	Herätä sisältäen mm., valvoa, heräillä, aamuyö, nukahtaa, uni,	3,8	3,1	2,4	9,3

Aihe nro	AVAINSANOJEN AVULLA LAADITUT TULKIN- NAT AIHEISTA	LÄÄKÄRILLÄ KÄYNTIEN MÄÄRÄ			Yht- eensä
		1	2- 3	>=4	
131	Unettomuus sisältäen mm., uniongelma ja lääki- tystä,	4,9	3,7	2,1	10,7
TOIMENPITEET					
89	Nostaa annos sisältäen mm. milligramma (+ eri- laisia lääkkeiden nimiä))	1,8	2,6	4,6	9,0
79	Uusia resepti	2,1	2,0	1,9	6,0
75	Tabletti , sisältäen mm. iltaisin, milligrammaa (+erilaisia lääkkeiden nimiä)	1,1	1,2	1,4	3,7
150	Kansaneläkelaitos, kela sisältäen mm. terapeutti, hakeminen, blausunto, terapia ja lääkitys	0,7	1,2	2,4	4,3
101	Kuntoutuspsykoterapia sisältäen mm. ajankoh- taisesti, tunnistaa, kokemus ja lääkitys	0,9	1,6	1,0	2,5
TYÖ: NEUVOTTELU TYÖN TEKEMISEN MAHDOLLISUUKSISTA					
7	Osallistuminen työhön sisältäen mm. työajan, työtehtävän, työmäärän, osasairauspäivärahan, työkyky- tai työterveysneuvottelun, esimiehen sekä sairausloman	2,2	2,6	3,3	8,1
60	Kontrolli paluusta työhön sisältäen mm. ensi_vii- kolla, paluu, ensi, palata, vointi sekä sairausloma ja työterveyspsykologi	2,2	4,4	6,5	13,1
59	Palautuminen , sisältäen mm. voimavara, kuormi- tus, kuormittua, arki, jaksaminen	1,5	1,7	1,9	5,1
49	Työyhteisöön kohdistuvat toiminta sisältäen mm. työyhteisön, tiimin, palaverin, työkaverin, työntekijän, esimiehen ja työterveyspsykologin.	3,4	3,5	3,1	10,0
11	Työasioiden mielessä pyöriminen sisältäen mm. huonosti nukkuminen ja työterveyspsykologi	4,2	3,3	2,1	9,5
PERHE					
43	Erota sisältäen mm. vanhempi, lapsuus,	2,0	2,3	2,2	6,5
139	Puoliso sisältäen mm. yhteinen, lapsi, perhe, pari- suhde	1,5	1,5	1,3	4,3

Taulukko 5. Työterveyshuollon mielenterveyden tuen aiheet ja niiden intensiteetit kolmessa käyntiryhmässä: vain kerran käyneet, 2–3 kertaa käyneet ja yli kolme kertaa käyneet ja aiheiden intensiteetit yhteensä tutkimusjaksolla.

Aiheista mielenterveyden oireisiin, arviointiin ja hoitoon liittyi kahdeksan aihetta, toimenpiteisiin viisi, työhön viisi ja perheeseen kaksi aihetta. Aiheista voidaan tunnistaa tilanteen tai oireen kuvausta sekä tekemistä ja toimijoita. Tilanteen ja oireen kuvausta on monessa aiheessa. Lääkityksen ja terapian suunnittelu ja arviointi ovat tekemisenä erillisinä keskeisinä aiheina. Toimijoista ovat lääkärin ja potilaan/asiakkaan lisäksi mukana muun muassa Kansaneläkelaitos, terapeutti, esimies, työpaikka ja työterveyspsykologi. Työterveyspsykologi avainsanana on mukana viidessä aiheessa: Toistuva keskivaikkea masennus (155); Ahdistus (123); Työyhteisöön kohdistuva toiminta (49); Kontrolli paluusta työhön (60); Työasioiden mielessä pyöriminen (11).

Työhön liittyvää viittä aihetta voi tulkita kokonaisuutena neuvotteluksi työn tekemisen mahdollisuuksista, mikä pitää sisällään laajan kirjon työterveyshuollon toimenpiteitä, työnantajan kanssa käytäviä keskusteluja sekä sosiaalivakuutuksen tukimuotoja. Tunnistetut aiheet kuvastavat tätä. Työntekijän tilanne voi vaatia osasairausvapaata ja osa-aikatyön organisointia työkyvyn tueksi (aihe 7). Sairauslomalta työhön paluu vaatii työntekijän tilanteen arviointia ja kontrollia (aihe 60). Kuormittavassa tilanteessa arvioidaan palautumisen mahdollisuutta ja työssä jaksamista (aihe 59). Lisäksi oli tarpeen käsitellä mielessä pyöriviä työasioita (aihe 11) ja pohtia työyhteisöön kohdistuvaa toimintaa (aihe 49).

Taulukossa 5 on tummennettu kolme intensiteetiltään korkeinta aihetta jokaisessa osaryhmässä. Vain kerran ja 2–3 kertaa lääkärin vastaanotolla käyneillä useimmin käsiteltiin ahdistukseen (123) ja unettomuuteen (131) liittyviä aiheita. Kerran käyneillä aiheista nousi esiin lisäksi työasiat (11) ja 2–3 kertaa kontrolli paluusta työhön (60). Yli kolme kertaa käyneillä aiheista useimmin käsiteltiin ahdistusta (123), lääkeannoksen nostamista (89) ja arvioitiin mahdollisuuksia työhön paluuseen. (60). Kaikilla käyneillä ahdistuksen tunnetta käsiteltiin usein. Näyttää siltä, että kun siirrytään kertakäynnistä yli neljään käyntiin lääkärillä, niin aiheissa liikutaan unen ja työasioiden käsittelystä hoidollisiin teemoihin, lääkitykseen ja terapiaan. Vastaavasti lisääntyy työkyvyn, jaksamisen ja työhön paluun arviointi. Kun tarkastellaan aiheiden intensiteettejä kaikkiaan (yhteensä sarake oikealla), niin useimmin käsiteltiin ahdistusta ja kontrollia paluusta työhön.

Ryhmittelimme vielä aiheet 10 teemaan taulukossa 6 ja teimme vastaavan tarkastelun kuin taulukon 5 kohdalla: mikä on osaryhmien aiheintensiteetiltään korkein teema?

Teema-aiheet ovat: Masennus (155+48), Uupumus (40+5), Ahdistus (123+125), Uni (126+131), Lääkitys (89+79+75), Terapia (150+101), Työhön osallistuminen ja jaksaminen (7+60+59), Työyhteisö ja työasiat (49+11) ja Perhe (43+139).

Taulukossa 6 esitetään tummennettuna aiheintensiteetiltään yleisin teema jokaisessa osaryhmässä. Vain yhden kerran lääkärin vastaanotolla käyneillä potilailla teema-aiheista käsiteltiin useimmin unettomuuteen liittyviä ongelmia. Sen sijaan 2–3 kertaa ja yli kolme kertaa käyneiden osaryhmissä käsiteltiin kummassakin useimmin työhön osallistumiseen ja jaksamiseen liittyvää teemaa. Kaikkiaan useimmin käsitelty teema-aihe oli työhön osallistuminen ja jaksaminen.

Teema-aiheet	Lääkärillä käyntien määrä			Yhteensä
	1	2-3	>=4	
Masennus	1,9	2,3	3,1	7,2
Uupumus	5,8	5,6	4,5	7,2
Ahdistus	2,7	3,1	3,1	15,8
Uni	8,7	6,8	4,5	20
Lääkitys	5,0	5,8	7,8	18,7
Terapia	1,8	2,4	3,7	6,8
Työhön osallistuminen ja jaksaminen	5,9	8,6	11,8	26,3
Työyhteisö ja työasiat	7,5	6,9	5,2	19,5
Perhe	3,5	3,9	3,5	10,8

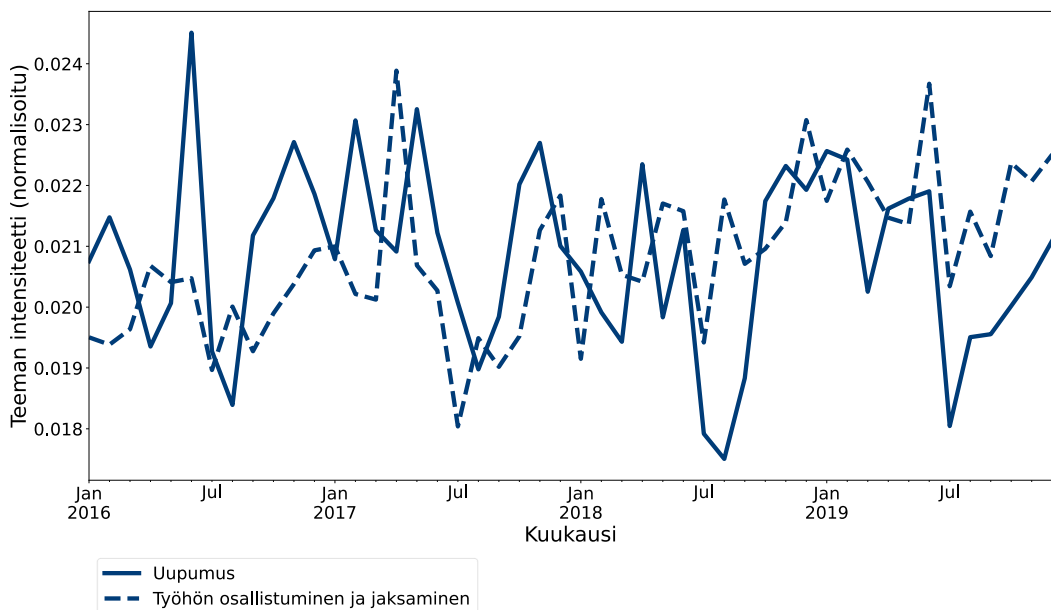
Taulukko 6: Työterveyshuollon mielenterveyden tuen aiheista muodostetut teemat ja niiden aiheintensiteetit kolmessa käyntiryhmässä.

3.2.2 Esimerkki teema-aiheiden kehittymisestä

Teemojen aiheintensiteetin kehittymistä voitiin tarkastella neljän vuoden jaksolla tammi-kuusta 2016 joulukuuhun 2019. Esimerkinomaisesti näytämme uupumus (jatkuva viiva ”uupumusteema”) ja ”työhön osallistuminen ja jaksaminen” (katkoviiva ”työ-teema”) -teemojen kehityskulkua kuvan 4 avulla. Kehityskulku on esitetty kuvaajana, jossa teeman aiheintensiteetti vaihtelee kuukaudesta toiseen. Teeman kuukausittainen intensiteetti on saatu laskemalla kuukauden dokumenteista teeman aiheiden todennäköisyydet yhteen ja laskemalla näiden todennäköisyyssummien keskiarvo kuukauden dokumenttien yli. Lisäksi kuvaajan käyrät on normalisoitu jakamalla käyrän arvojen summalla käyrien vertailun helpottamiseksi.

Alustavia teemojen aiheintensiteettien kehitystrendejä on tarkasteltu kahdella tavalla. Kuvassa voi havaita trendejä vuodenajan mukaan sekä kuukausittaisen intensiteetin mukaan. Kesäkuukausina (kesäkuu–elokuu) toistuu intensiteetin väheneminen ja syksyä

kohden nousu. Uupumus- ja työteemoja käsitellään työterveyshuollossa kesäkuukausina vähemmän. Työteeman korkeimmat intensiteetit ovat noususuunnassa vuoden 2017 kesästä lähtien eli työhön osallistumista ja jaksamista käsitellään työterveyshuollossa aiheena lisääntyvästi tutkimusjaksolla. Uupumusteeman korkeimmat intensiteetit ovat laskusuunnassa vuoden 2017 kesästä lähtien eli aiheen käsittelyn on vähentymään päin. Jatkossa tällaisten kehityskulkujen tarkastelu avaa monia uusia mahdollisuuksia tarkastella työterveyshuollon kannalta tärkeitä kehityskulkuja sekä ennakoida mahdollisia muutoksia esimerkiksi hoidon tarpeen kehittämisessä.



Kuva 4: Uupumus (kiinteä viiva) ja Työhön osallistuminen ja jaksaminen (katkoviiva) -teemojen intensiteettien kehitys tammikuusta 2016 joulukuuhun 2019.

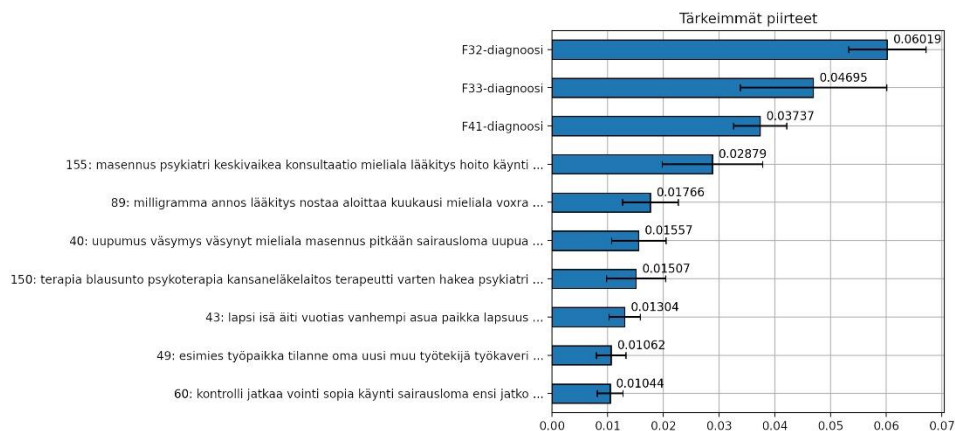
3.2.3 Aiheet hoidon pitkittymisen ennustajina

XGBoost-mallin kyky ennustaa hoitopolun venyminen vähintään viiteen hoitokäyntiin oli ROC-käyrän alle jäävän pinta-alan perusteella laskettuna keskimäärin 0,742, joka tarkoittaa kohtuullista erottelukykyä. Keskiarvo laskettiin toistamalla luokittelu 20 kertaa jakamalla aineisto eri tavoin 80 prosentin opetus- ja 20 prosentin testiaineistoihin. Käyttämällä luokittelussa vain potilaan diagnoosi- ja taustamuuttujia ilman tekstiaihemuuttujia tulokseksi saatiin 0,694, joka tarkoittaa heikkoa erottelukykyä. LDA:n

potilaskertomusteksteistä tuottamat aiheuuttajat siis lisäsivät ennusteen tarkkuutta. Ennusteen tarkkuuksien keskiarvojen ero oli myös tilastollisesti merkitsevä.

Ennustemallin tärkeimmät luokittelua selittävät muuttujat ovat esitettyinä kuvassa X. Hoidon pitkittymistä ennustivat voimakkaimmin F32-, F33- tai F41-diagnoosit, jonka potilas oli saanut käytyään lääkärin vastaanotolla. LDA:n löytämien 160 aiheen joukosta puolestaan merkittävimmitte tekijöiksi nousivat masennukseen, sen lääkinnälliseen hoitoon, uupumukseen, terapian hakemiseen, perheen tilanteeseen, työolosuhteisiin ja hoidon jatkuvuuteen liittyvät aiheet. On huomattava, että ennuste ei perustu vain yksittäisten aiheiden esiintymiseen, vaan myös aiheiden yhteisvaikutuksiin.

Mainittakoon, että XGBoostin ohella luokittelua kokeiltiin myös usealla muulla koneoppivalla luokittelumenetelmällä, mukaan lukien monikerroksinen perseptroni-neuroverkko (multilayer perceptron) ja kantavektorikonemallinnos (support vector machine), mutta niiden tuottamat AUROC-tulokset olivat XGBoostiin verrattuna heikompia.



Kuva 5: Ennustemallin kymmenen tärkeintä selittävää tekijää. Pylväs näyttää muuttujien tärkeysarvojen keskiarvon ja hakaset keskijajonnan, kun luokittelu suoritettiin 20 kertaa. Piirteiden tärkeys laskettiin XGBoostin gain-mittarilla, joka mittaa sitä, kuinka usein muuttujan esiintyminen mallin päätöspuissa parantaa mallin luokittelutarkkuutta.

Ennustemalliin seuloutui mukaan seitsemän keskeistä aihetta, jotka kuuluvat 20 keskeisen aiheen ryhmään. Aiheiden sisällölliset tulkinnat ovat edellä taulukossa 2 ja visualisoinnit ovat liitteessä 1.

3.2.4 Aihemallinnuksella saadun tiedon luotettavuus ja rajoittavat tekijät

Aihemallinnuksella saatujen aiheiden sisältämän tiedon luotettavuuteen vaikuttaa neljä tekijää: tekstin esikäsittely, dokumenttien määrä ja niiden pituus, aiheiden tulkinta ja mahdollisuus määrittellä aihe muuttujaksi (Isoaho, Gritsenko & Mäkelä, 2021). Arvioimme seuraavaksi näitä luotettavuuden kriteereitä omassa tutkimuksessaamme.

Esikäsittely suoritettiin huolellisesti (luku 2.4.3) ja se vastaa yleisesti hyväksytyjä datan käsittelymalleja (Isoaho ym. 2021). LDA-aihemallinnuksen opetukseen käytettiin aineistosta kaikki ne tekstidokumentit, joissa oli vähintään 50 sanaa. Tällaisia dokumentteja hoitokertomusaineistossa oli yhteensä 50 783 kappaletta. Tämä ylittää yleisesti hyväksytyn tason eli vähintään 1000 dokumenttia (ks. Isoaho ym. 2021). Totesimme myös, että analyysien kannalta tärkeää tietoa tuottavat myös lyhemmät 50–100 sanan hoitokertomusdokumentit, koska myös ne tuottivat relevantteja aiheita mallinnukseen.

Aihemallinnuksen tulkinnessa on käytetty 30 avainsanan listaa (kuva 3). Aihemallinnuksia tehtiin useimmilla aihemäärillä (48, 64, 96) 160 aiheen lisäksi. Tulkintaa oli mahdollista tehdä eri mallinnuksissa keskeisinä toistuvien aiheiden avulla ja koko avainsanalisan sanojen sekä avainsanojen aihekohtaisten osuvuuden avulla, mikä lisää osaltaan tiedon luotettavuutta (Isoaho ym. 2021).

160 aiheen ratkaisu valittiin pitkälti sen vuoksi, että sen avulla saatiin rakennettua ennustemalli, jolla kyettiin ennustamaan hoitopolun todennäköistä pitkittymistä tarkimmin. Siten ratkaisun aiheet toimivat myös muuttujan roolissa analyysimalleissa (Isoaho ym. 2021).

3.2.5 Aihemallinnuksen mahdollisuudet

Hoitotekstien analyysi koneoppimisen menetelmin osoitti, että työterveyshuollon lääkäreiden hoitokertomusteksteistä on mahdollista saada lisätietoa mielenterveyteen ja uniongelmiin liittyvistä avaintekijöistä työssä käyvässä väestössä. Mielenterveyteen liittyvien lääkäreiden hoitokertomustekstien hyödyntäminen tutkimuksessa tarjoaa uuden lähestymistavan työterveyden tutkimukseen.

Tekstianalyseissa havaittiin, että kun kyseessä on hoitotapahtumat, joihin liittyy mielenterveysdiagnosi, iso osa kertomusten aiheista liittyy mielenterveyden oireisiin ja niiden arviointiin, hoitoon ja toimenpiteisiin. Näiden lisäksi työn ja perheen tilanteet nousivat keskeisiksi mielenterveyteen liittyviksi aiheiksi.

Tämän osatutkimuksen ensimmäisessä vaiheessa tunnistimme keskeiset aiheet ja tulkitimme niiden sisältöjä avainsanojen avulla. Sitten muodostimme käyntimäärien

mukaiset kolme osaryhmää, joiden avulla saimme ymmärrystä aiheiden esiintymisen intensiteetistä eri ryhmissä. Lisäksi aiheet toimivat ennustajan roolissa ennustemallissa ja onnistuttiin ennustamaan hoitopolun pituutta.

Kaiken kaikkiaan havaitsimme, että hoitokertomusten hyödyntämiseen tarvitaan monitahoista osaamista ja yhteistyötä eri tieteenalojen välillä. Keskeisenä hankkeen tuloksena syntyikin lisäymmärrystä siitä, miten koneoppimista voidaan mahdollisesti hyödyntää kehitettäessä uusia tutkimusasetelmia ja uudenlaista työterveystutkimusta.

Hoitopolkujen tarkemmalla tutkimisella voisi saada vastauksia siihen, millaiset teemat ovat vedenjakajia mielenterveyden ja työkyvyn osalta. Jatkossa on mahdollisuus esim. ottaa tutkimusasetelmaan mukaan tietoja palveluiden käytöstä ennen mielenterveysdiagnoosin saamista. Voisiko tarkempi tieto vain kerran lääkäriä käyneistä henkilöistä antaa viitteitä siihen, millaiset aiheet ja palvelut eivät johda oireiden uusimiseen tai pahentumiseen?

Lisäksi analyyseissa tehtiin alustavia havaintoja aiheiden kehittymisestä. Tunnistimme muun muassa sekä vuodenaikavaihtelua että aihetrendien nousua ja laskua. Aihetrendien tarkastelu toimialoitain tai niiden yhdistäminen toimialan muihin tapahtumiin kuten sairauspoissaolotietoihin voisi olla seuraava askel monimutkaisen ja ajassa muuttuvan ilmiön tutkimuksessa.

Tekstien analyysissä hyödynsimme noin 70 000 hoitokertomustekstiä, jotka työterveyshuollossa toimivat lääkärit ovat kirjanneet. Aineisto ja siitä aineistolähtöisesti tunnistetut aiheet voidaan ymmärtää työssäkäyvien mielenterveyden tukemisen ekosysteemin erääksi tuotteeksi. Ekosysteemissä on paljon toimijoita, tekemistä ja päämääriä. Kun mielenterveyden muuttumista ajassa voidaan ennakoida teksteistä piirtyvien aiheiden avulla, tulee mahdolliseksi edistää työssä käyvien työkykyä ja mielen hyvinvointia uudella tavalla.

4 Yhteenveto

Kansainvälisessä tutkimuskirjallisuudessa on tunnistettu datatieteisiin liittyvät mahdollisuudet hyvin laajojen digitaalisten datamassojen aineistolähtöisessä analysoinnissa sekä ennustemallien rakentamisessa. Mielenterveyteen liittyvän työkyvyn tutkimusalueella tekoälyn ja koneoppimisen hyödyntäminen on kuitenkin ollut toistaiseksi vähäistä. *Paremmalla ennakoinnilla kestävämpään mielen hyvinvointiin työssä* -tutkimushankkeessa olemme pyrkineet kehittämään uudenlaista datalähtöistä työssä käyvän väestön mielenterveyden tutkimusta sekä luomaan työkaluja työterveyshuollon toiminnan tukemiseksi. Tavoitteenamme on ollut tuottaa tietoa mielenterveyden diagnooseihin liittyvistä ennustavista tekijöistä, hoidon pitkittymistä ennustavista tekijöistä sekä vahvistaa työterveyden asiantuntijoiden mahdollisuuksia tarjota varhaista tukea mielenterveys- haasteiden ja uniongelmiin hoidossa.

Hankkeen ensimmäisessä osatutkimuksessa tarkasteltiin työhyvinvointikyselyn käyttömahdollisuuksia mielenterveyteen tai uniongelmiin liittyvän lääkärin antaman diagnoosin ennustajana. Tulosten perusteella perinteiseen työterveys- ja hyvinvointitutkimukseen perustuva kysely tarjosi tietoa, jonka avulla voidaan ennustaa tulevaa mielenterveyteen liittyvää diagnoosia. Yli sataan kyselykysymykseen ja muutamaa taustamuuttujaan perustuva koneoppimisen malli pystyi huomattavasti parempaan ennustamiseen kuin satunnainen ennustaja tai muut testatut ennustemallit. Kiinnostavasti lähtökohtaisesti varsin yleisluontoinen työhyvinvointikysely, jota ei ole yksinomaan kehitetty työhön liittyvän mielenterveyden tai työkyvyn mittaamiseen tai ennakointiin, pystyi siis tuottamaan mielenterveystapahtumaa ennakoivaa tietoa, kun analyysit toteutettiin muuttujien välisiä yhteyksiä laaja-alaisesti tunnistavalla koneoppimisen mallilla.

Kyselydataan perustuvassa osatutkimuksessa tunnistettiin viisi olennaisinta avaintekijää, jotka ennakoivat mielenterveyden ongelmaan tai unihäiriöön liittyvää diagnoosia. Näistä kolme liittyi subjektiiviseen hyvinvointiin. Havaitsimme, että surumieliset ajatukset, voimakkaat stressin kokemukset ja toistuvat väsymyksen tunteet pitkin päivää ennustivat mielenterveysdiagnoosin tai diagnosoidun unihäiriön kohonnutta todennäköisyyttä seuranta-aikana. Tämä on ymmärrettävää, sillä näihin kyselyn kysymyksiin sisältyy sellaisia ulottuvuuksia, jotka pitkään jatkuessaan voivat johtaa masennukseen, ahdistushäiriöihin, uupumukseen tai unettomuuteen. Tai kriittisemmin tarkastellen: surumielisyyttä, stressiä ja väsymystä voidaan alkaa lääketieteellisen järjestelmän piirissä nimittämään depressioksi tai ahdistushäiriöksi. Samalla se voi johtaa mielialalääkitykseen ja muihin hoitomuotoihin. Selittävässä tekijöissä oli kuitenkin eroja ikä- ja sukupuoliryhmien välillä; esimerkiksi arvottomuuden kokemus ennusti diagnoosia enemmän miehillä kuin naisilla. Sukupuolella ja iällä myös itsellään oli tulevaan diagnoosiin liittyvää

ennustearvoa, kun nuoremmat henkilöt ja naiset saivat todennäköisemmin jonkun tutkituista diagnooseista.

Kuitenkin koneoppiseen perustuvan luokittimen kyky ennustaa tulevaa mielenterveyden diagnoosia jäi kohtuullisen maltilliseksi, kun diagnoosia ennustavan tiedon päälähteenä oli vastaajien yhden kerran täyttämä työhyvinvointikysely. Vaikuttaa siltä, että pelkkien työhyvinvointikyselyvastausten sekä iän ja sukupuolen avulla ei vielä voida luotettavasti ennustaa mielenterveyteen tai unihäiriöön liittyvää diagnoosia yksilötasolla. Ennuste on syytä nähdä pikemminkin suuntaa antavana. On mahdollista, että tämän kaltaisista välineistä voi kuitenkin olla apua tunnistettaessa riskiryhmiä laajemmin työikäisessä väestössä.

Toisessa osatutkimuksessa lähdimme liikkeelle lääkärin kirjaamista potilastapauksista, jolla oli jo lähtökohtaisesti jokin hiljattain saatu mielenterveyteen liittyvä diagnoosi taustallaan, muttei muuten lähiaikoina todennettua hoitohistoriaa mielenterveyden takia saman työterveyspalvelun piiristä. Tässä tutkimuksessa keskeiseksi tutkimusaineistoksi ja ennustavaksi materiaaliksi valitsimme hoitotapahtumien yhteydessä rutiininomaisesti kertyvät hoitokertomukset. Koneoppimiseen perustuva analyysimme pohjautui asetelmaan, jossa ennustimme mielenterveyteen tai uniongelmiin liittyvien hoitotapahtumien pitkittymistä hyödyntämällä kahden ensimmäisen hoitokäynnin hoitokertomustekstiä, diagnooseja sekä rakenteellisia taustamuuttujia kuten ikäryhmää. Hoitotapahtumien pitkittymisen kriteeriksi asetimme yli neljä hoitokäyntiä. Tässä asetelmassa keskeisimpänä mielenterveyden hoidontarpeen pitkittymistä ennustavana aineistona käytimme ”luonnollisen kielen tekstejä” ja niissä ilmeneviä sanoja. Tämä tarkoitti käytännössä hyvin haastavaa aineiston työstövaihetta sekä pitkäa alustavien analyysien vaihetta ennen kuin pääsimme varsinaisiin tuloksiin johtaneisiin analyysiin.

Luonnollisen kielen analyysissä löydettyjen 160 aiheen joukosta merkittävimmiksi aihekokonaisuuksiksi nousivat masennukseen, sen lääkinnälliseen hoitoon, uupumukseen, terapian hakemiseen, perheen tilanteeseen, työolosuhteisiin ja hoidon jatkuvuuteen liittyvät aiheet. Merkittävimmät ennustavat tekijät olivat kuitenkin itse hoitokertomuksiin sisältyneet F32-, F33- ja F41-diagnoosit. Tulokset viittaavat kokonaisuudessaan siihen, että mielenterveysperusteisten työterveyshuollon hoitokäyntien pitkittymisen ennakoinnissa luonnolliseen kieleen pureutuvat koneoppisen menetelmät voivat tuottaa tietystä määrin lisäarvoa, kun käytössä on riittävästi relevanttia tekstimassaa, taustamuuttajia ja tutkimusjoukkoa. Koneoppimismenetelmiin perustuva laajoihin tekstimassoihin perustuva datalähtöinen tutkimus voikin tarjota näin uusia lähestymistapoja työkykyyn ja mielenterveyteen liittyvään empiiriseen tutkimukseen sekä mahdollisesti myös

parantaa työterveyshuollon kykyä toteuttaa ennaltaehkäisevää tehtäväänsä mielenterveyden hoidossa ja työkyvyn tukemisessa.

Tutkimushankkeessamme datatieteilijöiden kirjoittamat kommentorivit tuotettiin tutkimuskäyttöä varten. Jatkossa niitä on mahdollista integroida osaksi työterveyshuollon palvelujärjestelmiä ja parempaa tiedolla johtamista. Käytännön sovelluksia silmällä pitäen ehdotamme, että koneoppiseen perustuvia työkaluja olisi mahdollista käyttää esimerkiksi terveydenhuollon työkuormituksen ja henkilöresurssien ohjauksen apuvälineenä. Sen sijaan kummankaan osatutkimuksen pohjalta koneoppimista ei voi suositella käytettäväksi yksilökohtaisessa mielenterveysriskien ennakoinnissa vastaanotoilla, koska yksilötasolla mallinnus sisältää liikaa epävarmuutta.

Koneoppisen pohjalta on siis mahdollista kehittää älykkäitä sovelluksia, jotka voivat auttaa ennakoimaan esimerkiksi mielenterveyden hoidon tarpeita työterveyshuolloissa. Tämä voi auttaa tulevaisuuden työterveyshuoltoa, ja terveydenhuoltoa ylipäätään, kun esimerkiksi terveyden ja hyvinvoinnin asiantuntijoiden aikaresurseja pyritään allkoiimaan ja suuntaamaan mahdollisimman osuvasti ja tarkoituksen mukaisesti.

Merkittävä rajoitus tutkimusasetelmassa oli se, että analyysiin sisällytettiin vain työterveyspalvelujen tarjoajan järjestelmiin kirjatut mielenterveysdiagnoosit. Osa aineiston henkilöistä on kuitenkin saattanut hakea hoitoa muulta palveluntuottajalta, jolloin osa diagnooseista ja muista tapahtumista ei ole sisällytetty aineistoon. Tämä voi osaltaan selittää käytetyn luokittimen taipumusta yliennustaa diagnoosien määrää tutkimusväestössä suhteessa havaittuihin diagnooseihin.

Aikaisempia esimerkkejä koneoppimismallien hyödyntämisestä työssä käyvän mielenterveysdiagnoosien ennustamisessa pitkittäistutkimuksessa ei kansainvälisestä tutkimuskirjallisuudesta juuri löydy. Muihin väestöryhmiin kohdistuvissa tutkimuksissa puolestaan on harvoin hyödynnetty kliinisessä ympäristössä luokiteltuja mielenterveyshäiriötä, vaan tutkimuksessa on pitkälti hyödynnetty itsearvioitua mielenterveyttä, joka on mitattu kyselymittarein. Esimerkiksi Tate ym. (2014) pyrkivät ennustamaan rekisteritietojen pohjalta nuorten itsearvioitua mielenterveyden haasteita saavuttaen ennustearvoja, jotka olivat lähellä omia mallinnuksiamme. Voidaan kuitenkin todeta, että käyttämämme aineisto on tulosmuuttujien osalta vahvempi, koska pystyimme ennustamaan hoitojärjestelmän piirissä tehtyjä todellisia mielenterveyteen liittyviä diagnooseja.

Datatieteen mahdollisuuksia on alettu viime aikoina soveltaa tuloksetkaasti esimerkiksi psykiatrian (Fusal-Poli ym. 2018) ja syöpätutkimuksen (Zhu ym. 2020) alueella, mutta silti vielä julkaisemattoman kirjallisuuskatsauksemme (Varje ym. 2022) mukaan työhön ja mielenterveyteen liittyvien laadukkaiden koneoppimiseen perustuvien tutkimusten

määrä on toistaiseksi hyvin rajallinen. Tällä hetkellä näyttää siltä, että datalähtöiset lähestymistavat ja laskennalliset tieteet eivät tule korvaamaan perinteisiä tutkimustapoja mielen terveyden ja työkyvyn tutkimuksessa, mutta ne voivat kyllä merkittävästi täydentää tutkimuskentän lähestymistapoja ja vahvistaa tutkimustiedon näyttöön perustuvaa luonnetta. Tällä hetkellä koneoppimisen roolin voi nähdä sekä perinteisten että uuden tyyppisten tietolähteiden louhinnan potentiaalisena instrumenttina, joka perustuu kasvavaan laskentatehoon.

Koneoppimiseen liittyvät uudet lähestymistavat mielen terveyden ja työkyvyn tutkimuksen alueella voivat jatkossa toimia monella tapaa kenttää uudistavalla tavalla. Ne voivat muun muassa kyseenalaistaa yksinomaan ennalta rajattuun dataan, kuten tietyn tutkimusperinteen kyselyihin, perustuvia kanonisoituja oletuksia. Ne voivat myös vahvistaa mielen terveyden oikea-aikaista hoitoa ja edesauttaa psyykkiseen työkykyyn liittyvää kehittämistoimintaa. Näin koneoppimisella voi olla vaikutuksia niin tieteellisen tutkimukseen kuin käytännön työterveyden kehittämistyöhön.

Tutkimuksemme kuitenkin hyvin osoittaa, etteivät koneoppimiseen perustuvat ennustemallit ole erehtymättömiä. ”Tekoälyn” etuna ihmismieleen verrattuna on sen kyky väsymättä ja nopeasti hyödyntää hyvin laajoja datatiedostoja sekä etsiä niistä vaikeasti havaittavia teemojen/riskitekijöiden yhdistelmiä. Tämä voi osaltaan auttaa ennalta ehkäisevien toimintatapojen kehittymisessä, vaikkei se lääkärin ja muiden asiantuntijoiden ammattitaitoa voi korvatakaan. Menetelmiä voi soveltaa myös esimerkiksi työpaikalla kertyviin digitaalisiin aineistoihin, mutta tämäkin vaatii runsasta pohjatyötä sekä yhteistyötä sisältö- ja menetelmäasiantuntijoiden välillä.

Tulevaisuudessa tietokoneiden laskentatehon ja koneoppimisen menetelmien kehitys voi edesauttaa työlääkätieteen, epidemiologian, psykologian, sosiaalitieteiden ja muiden mielen terveyttä ja työelämää tutkivien tieteenalojen tutkimusta. Tämä voi lisätä sekä systemaattisesti kerättyjen (esim. hyvinvointikyselyt) että luonnollisesti kertyvien aiemmin hyödyntämättömien datojen käyttöä. Kehitys voi parhaimmillaan vahvistaa myös työkykyä tukevien järjestelmien joustavuutta ja toimivuutta, kun työntekijään, työorganisaatioon ja hyvinvointiin liittyvistä digitaalisista datoista voidaan tuottaa esimerkiksi työyksiköihin tai ammattiryhmiin liittyviä havaintoja ilman pitkiä aikaviiveitä sekä kehittää samalla joustavampia työkyvyn johtamiseen soveltuvia apuvälineitä. Työkyvyn tukemiseen datavirtakoosteet ja korrelaatioihin perustuvat ennustemallit eivät jatkossakaan yksinomaan kuitenkaan riitä, vaan työkyvyn johtaminen ja työhyvinvoinnin tuki tarvitsevat osaavia ja riittävästi resursoituja ihmisiä tekemään työntekijöiden hyvinvointia tukevia arkisia tekoja.

5 Lähteet

Arkaprabha, S. & Ishita, B. (2019). Screening of anxiety and depression among seafarers using machine learning technology. *Informatics in Medicine Unlocked*, 16, 100228.

Beaulieu-Jones, B., Finlayson, S. G., Chivers, C., Chen, I., McDermott, M., Kandola, J., ... & Naumann, T. (2019). Trends and focus of machine learning applications for health research. *JAMA network open*, 2(10), e1914051-e1914051.

Blei, D. M. (2012). Probabilistic topic models. *Communications of the ACM*, 55(4), 77-84.

Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent dirichlet allocation. *Journal of machine Learning research*, 3(Jan), 993-1022.

Blomgren, J. & Perhoniemi, R. (2021). Increase in sickness absence due to mental disorders in Finland: Trends by gender, age and diagnostic group in 2005–2019. *Scandinavian Journal of Public Health*.

Chen, T. & He, T. (2014). Higgs boson discovery with boosted trees. *HEPML'14: Proceedings of the 2014 International Conference on High-Energy Physics and Machine Learning*, 42, 69-80.

Chen, T. & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794

Chisholm, D., Sweeny, K., Sheehan, P., Rasmussen, B., Smit, F., Cuijpers, P. & Saxena, S. (2016). Scaling-up treatment of depression and anxiety: A global return on investment analysis. *The Lancet Psychiatry*, 3, 415–424.

DeLong, E. R., DeLong, D. M., Clarke-Pearson, D. L. (1998). Comparing the area under two or more correlated receiver operating characteristic curves: a nonparametric approach. *Biometrics* 44, 837–844

Doki, S., Sasahara, S., Hori, D., Oi, Y., Takahashi, T., Shiraki, N., Ikeda, Y., Ikeda, T., Arai, Y., Muroi, K. & Matsuzaki, I. (2021). Comparison of predicted psychological distress among workers between artificial intelligence and psychiatrists: A cross-sectional study in Tsukuba Science City. *Japan BMJ Open*, 11, e046265.

Eichstaedt, J. C., Smith, R. J., Merchant, R. M., Ungar, L. H., Crutchley, P., Preotiuc-Pietro, D., Asch, D. A. & Schwartz, H. A. (2018). Facebook language predicts depression in medical records. *PNAS*, 115(44), 11203–11208.

Fattah, H. M. A., Hasan, K. M. A. & Das, S. (2021). A voting classifier for the treatment of employees' mental health disorder. Paper presented at the 2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI).

Fawcett, T (2006). An introduction to ROC analysis. *Pattern Recognition Letters* 27, 861-874.

Forsström, J (1995). Testien diagnostisen arvon mittaaminen ROC-käyrän avulla. *Duodecim*, 111(3), 237-

Fusal-Poli, P., Hijazi, Z., Stahl, D., Steyerberg, E.W. (2018). The Science of Prognosis in Psychiatry: A review. *JAMA Psychiatry*, 75(12), 1289-97.

García-Herrero, S., Lopez-Garcia, J. R., Herrera, S., Fontaneda, I., Báscones, S. M., Mariscal. M. A. (2017). The influence of recognition and social support on European health professionals' occupational stress: A demands-control-social support-recognition Bayesian network model. *BioMed Research International*, 2017, 4673047.

Grzadzielewska, M. (2021). Using machine learning in burnout prediction: A survey. *Child and Adolescent Social Work Journal*, 38(2), 175–180.

Halevi, G., Moed, H., & Bar-Ilan, J. (2017). Suitability of Google Scholar as a source of scientific information and as a source of data for scientific evaluation—Review of the Literature. *Journal of Informetrics*, 11(3), 823–834.

Hashmi, A. (2018). Application of data mining techniques for occupational stress management (Doctoral dissertation). Shri Jagdishprasad Jhabarmal Tibrewala University.

Hashmi A. & Yadav, S., K. (2018). A systematic review of computational methods for occupational stress modeling based on subjective and objective measures. *International Journal of Computer Sciences and Engineering*, 6(6), 456–470.

Havaei, F., Ji, X., R., MacPhee, M. & Straight, H. (2021). Identifying the most important workplace factors in predicting nurse mental health using machine learning techniques. *BMC Nursing*, 20, 216.

He, G., Veldkamp, B. P. & Vries, T. (2012). Screening for posttraumatic stress disorder using verbal features in self narratives: A text mining approach. *Psychiatry Research*, 198(3), 441–447.

Herrero, G. S., Saldaña, M. A. M., Rodriguez, J. G., & Ritzel, D. O. (2012). Influence of task demands on occupational stress: gender differences. *Journal of Safety Research*, 43(5–6), 365–374.

Hirschberg, J. & Manning, C. D. (2015). Advances in natural language processing. *Science*, 349(6245), 261–266.

Isoaho, K., Gritsenko, D., & Mäkelä, E. (2021). Topic modeling and text analysis for qualitative policy research. *Policy Studies Journal*, 49(1), 300–324.

Jackson, R. G., Patel, R., Jayatilleke, N., Kolliakou, A., Ball, M., Gorrell, G., Roberts, A., Dobson, R. J. & Stewart, R. (2017). Natural language processing to extract symptoms of severe mental illness from clinical text: the Clinical Record Interactive Search Comprehensive Data Extraction (CRIS-CODE) project. *BMJ Open*, 7, e012012.

Kanerva J, Ginter F, Miekka N, ym. Turku neural parser pipeline. An end-to-end system for the CoNLL 2018 shared task. Kirjassa: Zeman D, Hajič J, toim. Proceedings of the CoNLL 2018 Shared Task. Multilingual parsing from raw text to universal dependencies. Bryssel: The Association for Computational Linguistics 2018; 133–42.

Kao, A. & Poteet, S. R. (2007). *Natural language processing and text mining*. London: Springer.

Karystianis, G., Nevado, A. J., Kim, C.-H., Dehghan, A., Keane, J. A. & Nenadic, G. (2018). Automatic mining of symptom severity from psychiatric evaluation notes. *International Journal of Methods in Psychiatric Research*, 27, e1602.

Koleck, T. A., Dreisbach, C., Bourne, P. E. & Bakken, S. (2019). Natural language processing of symptoms documented in free-text narratives of electronic health records: A systematic review. *Journal of the American Medical Informatics Association*, ocy173.

Laaksonen, M., Blomgren, J. & Perhoniemi, R. (2021). Mielenterveyssyistä alkavat eläkkeet ovat yleistyneet nuorilla mutta vähentyneet vanhemmissa ikäryhmissä. *Lääkärilehti*, 76(36), 1889–1893.

Ladstätter, F., Garrosa, E., Badea, C. & Moreno-Jimenez, B. (2010). Application of artificial neural networks to a study of nursing burnout. *Ergonomics*, 53(9), 1085–1096.

Lee, Y., Chou, W., Chien, T. Chou, P., Yeh, Y. & Lee, H. (2020). An app developed for detecting nurse burnouts using the convolutional neural networks in Microsoft Excel: Population-based questionnaire study. *JMIR Medical Informatics*, 8(5), e16528.

Lee Y. & Shin, S. (2010). Job stress evaluation using response surface data mining, *International Journal of Industrial Ergonomics*, 40(4), 379–385.

Machine Learning for Health—2018 interactive topic modeling. ML4H—2018 Topic Modelling. <https://ml4health.github.io/2018/viz/>. Accessed September 2, 2019.

Martin, A., Shann, C. & LaMontagne, A. D. (2019). Promoting workplace mental wellbeing. In U. Bültmann & J. Siegrist (Toim.), *Handbook of disability, work and health. Handbook Series in Occupational Health Sciences*, vol 1 (ss. 1–19). Springer.

McIntosh, A. M., Stewart, R., John, A., Smith, D. J., Davis, K., Sudlow, C., Corvin, A., Nicodemus, K. K., Kingdon, D., Hassan, L., Hotopf, M., Lawrie, S. M., Russ, T. C., Geddes, J. R., Wolpert, M., Wölbert, E. & Porteous, D. J. (2016). Data science for mental health: A UK perspective on a global challenge. *Lancet Psychiatry*, 3(10), 993–998.

Reddy, U. S., Thota, A. T. & Dharun, A. (2018). Machine Learning Techniques for Stress Prediction in Working Employees. Paper presented at the 2018 IEEE International Conference on Computational Intelligence and Computing Research (ICIC).

Russ, T. C., Woelbert, E., Davis, K. A. S., Hafferty, J. D., Ibrahim, Z., Inkster, B., John, A., Lee, W., Maxwell, M., McIntosh, A. M., Stewart, R. & the MQ Data Science group. (2019). How data science can advance mental health research. *Nature Human Behaviour*, 3(1), 24–32.

Sievert, C., & Shirley, K. (2014). LDAvis: A method for visualizing and interpreting topics. In *Proceedings of the workshop on interactive language learning, visualization, and interfaces* (pp. 63–70).

Tate, A.E., McCabe, R.C., Larsson, H., Lundström, S., Lichtenstein, P., Kuja-Halkola, R. (2020). Predicting mental health problems in adolescence using machine learning techniques. *PLOS ONE*, 15, e0230389.

Tiffin, P. A. & Paton, L. W. (2018). Rise of the machines? Machine learning approaches and mental health: opportunities and challenges. *British Journal of Psychiatry*, 213(3), 509–510.

Torraco, R. J. (2005). Writing integrative literature reviews: Guidelines and examples. *Human Resource Development Review*, 4(3): 356–367.

Uddin, J. M. I., Fatema, K. & Dhar, P. K. (2020). Depression risk prediction among tech employees in Bangladesh using Adaboosted Decision Tree. Paper presented at the 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE).

Vahteristo, A. & Kinnunen, U.-M. (2019). Tekoälyn hyödyntäminen terveydenhuollossa terveystieteiden ja riskitekijöiden tunnistamiseksi ja ennustamiseksi. *Finnish Journal of eHealth and wWelfare*, 11(3), 198–209.

Varje, P., Mustakallio, M., Väänänen, A. (2022). Machine learning in the analysis of mental health at work: An integrative literature review. *Käsikirjoitus arvioitavana*.

Vincent, P. M. D. R., Mahendran, N., Nebhen, J., Deepa, N., Srinivasan, K. & Hu, Y. (2021). Performance assessment of certain machine learning models for predicting the major depressive disorder among IT professionals during pandemic times. *Computational Intelligence and Neuroscience*, 2021, 9950332.

Väänänen, A., Anttila, E., Turtiainen, J. & Varje, P. (2012). Formulation of work stress in 1960–2000: Analysis of scientific works from the perspective of historical sociology. *Social Science & Medicine*, 75(5), 784–794.

Wang, W., Hernandez, I., Newman, D. A., He, J. & Bian J. (2016). Twitter analysis: Studying US weekly trends in work stress and emotion. *Applied Psychology*, 65, 355–378.

Wu, X., Zhu, X., Wu, G.-Q. & Ding, W. (2014). Data mining with big data. *IEEE Transactions on Knowledge and Data Engineering*, 26(1), 97–107.

Zhu, W., Xie, L., Han, J., Guo, X. (2020). The Application of Deep Learning in Cancer Prognosis Prediction. *Cancers*, 12, 603.

LIITTEET

Liite 1. Työterveyskyselyn kuvaus

Työterveyskysely sisälsi yhteensä 135 kysymystä aihealueilta Sairaudet, oireet, lääkkeiden käyttö; Näkö- ja kuulo-ongelmat; Liikunta, painonhallinta ja diabetesriski; Kipu ja fyysisen toiminnan haitta; Uni ja vireystila; Mieliala; Hyvinvointi työssä; Tupakointi ja päihtet; Suun terveys. Taulukossa L1 on esitetty tarkemmin 18 tutkimuksen kannalta tärkeintä kysymystä iän ja sukupuolen lisäksi. Kaikkiaan analyysiin sisällytettiin 104 kysymysmuuttujaa, joissa osa kysymyksistä oli laskettu summamuuttujiksi (esimerkiksi eri alkoholijuomien kulutus yhdistetty alkoholin kokonaiskulutukseksi).


AIHEALUE	OHJE	KYSYMYS	VASTAUSVAIHTOEHDOT	KYSYMYKSEN TUNNUS
Sairaudet, oireet, lääkkeiden käyttö	Merkitse kaikki oireet, joita sinulla on ollut kahden viime vuoden aikana	Toistuvaa päänsärkyä	Kyllä, Ei	oire_päänsärky
		Ahdistus- tai paniikkioireita		oire_ahdistus
Mieliala	Merkitse jokaisesta ryhmästä se vaihtoehto, joka parhaiten kuvaa tilannetasi viimeksi kuluneen kuukauden aikana.	Kärsin unettomuudesta	Ei lainkaan, Jonkin verran, Melko paljon, Erittäin paljon	mieliala_unettomuus
		Tunsin itseni surumieliseksi		mieliala_suru
		Minusta tuntui, että kaikki vaati ponnistusta		mieliala_ponnistelu
		Tunsin itseni tarmottomaksi		mieliala_tarmottomuus
		Tulevaisuus tuntui toivotonmalta		mieliala_toivotontulevaisuus
		Nautin elämästäni		mieliala_elämästänauttiminen
		Tunsin, että kaikki ilo on hävinnyt elämästä		mieliala_hävinnytילו
		Tunsin, ettei alakuloisuuteni hellittänyt edes perheeni tai ystävien avulla		mieliala_alakuloisuus

AIHEALUE	OHJE	KYSYMYS	VASTAUSVAIHTOEHDOT	KYSYMYKSEN TUNNUS
Kipu ja fyysisen toiminnan haitta	Arvioi asteikolla 0-10, kuinka paljon haittaa sinulle aiheutuu selkä-, niska-, hartia-, olkapää- tai nivelvaivoistasi (0=ei lainkaan haittaa, 10=pahin mahdollinen haitta).	Haitta työssä	0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10	fyysinenhaitta_työssä
Uni ja viireystila		Oletko kokenut vaikeuksia nukahtaa viimeksi kuluneiden kolmen kuukauden aikana?	En koskaan tai harvemmin kuin kerran kuussa, Harvemmin kuin kerran viikossa, 1–2 päivänä viikossa, 3–5 päivänä viikossa, Päivittäin tai lähes päivittäin	uni_nukahtamisvaikeudet
		Tunnetko itsesi uupuneeksi päiväsaikaan?		uni_uupunutpäivisin
		Tunnetko itsesi väsyneeksi päivisin?		uni_väsynytpäivisin
Hyvinvointi työssä		Viikonlopun jälkeen olen palautunut työkuormituksesta ja mieleni on virkistynyt	Hyvin usein/aina, Melko usein, Silloin tällöin, Melko harvoin, Erittäin harvoin/ei koskaan	työvapaaaika_viikonloppuna
		Perhepiirin ongelmat häiritsevät työtäni		työvapaaaika_perheongelmat
		Tunnen olevani tyhjiin puserrettu työstäni		työkuormitus_tyhjiinpuserrettu
		Stressaantuneena ihminen tuntee itsensä jännittyneeksi, levottomaksi, hermostuneeksi ja/tai ahdistuneeksi, tai hänen on vaikea nukkua asioiden vaiatessa jatkuvasti mieltä. Tunnen tällaista stressiä.		työkuormitus_stressi


Taulukko L1. Tutkimuksen kannalta tärkeimmät työterveyskyselyn kysymykset.

Liite 2. Visualisointivälineen avulla tuotetut aiheiden avainsanalizat teemoittain.

Masennus: Keskivaikea masennus




Top-30 Most Relevant Terms for Topic 155 (1.9% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Masennus: Tutkimus




Top-30 Most Relevant Terms for Topic 48 (1.4% of tokens)




Overall term frequency (Blue bar)
Estimated term frequency within the selected topic (Red bar)

1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Uupumus: Jo_pitkään uupumus



Top-30 Most Relevant Terms for Topic 40 (1.9% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Uupumus: Jatketaan_sairauslomaa




Top-30 Most Relevant Terms for Topic 5 (1.1% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = λ * p(w | t) + (1 - λ) * p(w) / p(w); see Sievert & Shirley (2014)

Ahdistus: Ahdistus




Top-30 Most Relevant Terms for Topic 123 (3.3% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))]; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Ahdistus: Ahdistusoireilu




Top-30 Most Relevant Terms for Topic 125 (2.7% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Uni: Herätä




Top-30 Most Relevant Terms for Topic 126 (2.5% of tokens)




Overall term frequency
Estimated term frequency within the selected topic

- saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
- relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Uni: Unettomuus




Top-30 Most Relevant Terms for Topic 131 (2.3% of tokens)




Overall term frequency (Blue bar)
Estimated term frequency within the selected topic (Red bar)

1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Lääkitys: Nostaa annos




Top-30 Most Relevant Terms for Topic 89 (4% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Lääkitys: Uusia resepti




Top-30 Most Relevant Terms for Topic 79 (1.7% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Lääkitys: Tabletti



Top-30 Most Relevant Terms for Topic 75 (1.3% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Terapia: Kansaneläkelaitos




Top-30 Most Relevant Terms for Topic 150 (2.1% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Terapia: Kuntoutuspsykoterapia




Top-30 Most Relevant Terms for Topic 101 (2.8% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Työhön osallistuminen ja jaksaminen: Osallistuminen työhön



Top-30 Most Relevant Terms for Topic 7 (3.2% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Työhön osallistuminen ja jaksaminen: Kontrolli paluusta työhön




Top-30 Most Relevant Terms for Topic 60 (4.9% of tokens)




Overall term frequency
Estimated term frequency within the selected topic

1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))]; see Chuang et. al (2012)
2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Työhön osallistuminen ja jaksaminen: Palautuminen




Top-30 Most Relevant Terms for Topic 59 (2.1% of tokens)




Overall term frequency (Blue bar)
Estimated term frequency within the selected topic (Red bar)

- saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
- relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Työyhteisö ja työasiat: Työasioiden mielessä pyöriminen




Top-30 Most Relevant Terms for Topic 11 (2% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)

2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Perhe: Erot




Top-30 Most Relevant Terms for Topic 43 (3.1% of tokens)




1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Perhe: Puoliso



Top-30 Most Relevant Terms for Topic 139 (1.6% of tokens)



1. saliency(term w) = frequency(w) * [sum_t p(t | w) * log(p(t | w)/p(t))] for topics t; see Chuang et. al (2012)
 2. relevance(term w | topic t) = $\lambda * p(w | t) + (1 - \lambda) * p(w | t)/p(w)$; see Sievert & Shirley (2014)

Mielenterveysongelmien ennaltaehkäisyn kannalta on tärkeää lisätä ymmärrystä ongelmien taustalla olevista kehityskulkuista ja kehittää menetelmiä niiden ennakointiin. Koneoppimismenetelmiin ja työterveyshuollon digitaalisiin potilasaineistoihin perustuvassa tutkimuksessa ennustettiin tulevaa mielenterveysdiagnoosia työterveyskyselyn pohjalta. Lisäksi hoidon pitkittymistä ennustettiin mielenterveyteen tai unihäiriöihin liittyvistä kahdesta ensimmäisestä hoitokäynistä muodostuneista materiaaleista. Analyyseissä hyödynnettiin luonnollisen kielen prosessointia ja luokittelumallinnusta. Hankkeessa onnistuttiin automaattisesti seulomaan aineistoista mielenterveysdiagnoosia tai mielen-terveyden hoitosarjan pitkittymistä ennustavia piirteitä ja tuottamaan mielenterveystapahtumia ja unihäiriöitä ennustavia mallinnuksia. Käytetyt lähestymistavat saattavat jatkossa osoittautua hyödyllisiksi sekä psyykkisen työkyvyn tutkimuksessa että käytännön ennaltaehkäisyn ja hoitotyön tukena.



Työsuojelurahasto
Arbetskyddsfonden
The Finnish Work Environment Fund

Työterveyslaitos
Arbetshälsoinstitutet
Finnish Institute of Occupational Health

PL 40, 00032 Työterveyslaitos

www.ttl.fi

ISBN 978-952-391-026-3 (PDF)

