

Hanna Lemmetty

**TEKOÄLYN HYÖDYNTÄMINEN HENKILÖSTÖ- JA
PALKANLASKENTAJÄRJESTELMÄSSÄ**



JYVÄSKYLÄN YLIOPISTO
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA
2020

TIIVISTELMÄ

Lemmetty, Hanna

Tekoälyn hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä

Jyväskylä: Jyväskylän yliopisto, 2020, 83 s.

Tietojärjestelmätiede, pro gradu -tutkielma

Ohjaaja: Seppänen, Ville

Tekoälyn hyödyntäminen on vähitellen yleistymässä, mutta organisaatioissa on yhä epävarmuutta tekoälyn soveltuvuudesta omaan liiketoimintaan ja tekoälyyn tehtävien investointien kannattavuudesta. Tämän pro gradu -tutkielman tarkoituksena oli selvittää tekoälyn hyödyntämistä henkilöstö- ja palkanlaskentajärjestelmässä. Tekoälyn hyödyntämistä tarkasteltiin informaatioteknologian (IT) omaksumisen näkökulmasta organisaatiotasolla. Kvalitatiivisen tutkimuksen aineisto kerättiin haastattelemalla henkilöstö- ja palkanlaskentajärjestelmän kehitykseen ja ylläpitoon osallistuvia IT-alan työntekijöitä. Tulokset vahvistivat aiempia käsityksiä, joiden mukaan tekoälystrategian ja osaamisen puute hidastavat tekoälyn teknologioiden omaksumista organisaatioissa. Uusien teknologioiden käyttöönotto on välttämättömyys järjestelmäkehityksessä, mutta tulosten mukaan tekoälyn teknologioiden omaksuminen ei ollut samalla tavalla mahdollista kuin perinteisten järjestelmäkehitysmenetelmien. Tuloksista voidaan päätellä, että tekoälyn teknologioiden omaksumista voidaan edistää riittävillä resursseilla ja nostamalla organisaation osaamistasoa koulutuksella, rekrytoinnilla tai alihankinnalla. Automaatiota käytetään jo nyt monipuolisesti henkilöstö- ja palkanlaskentajärjestelmissä. Tästä huolimatta havaittiin, että tekoälyn teknologiat tarjoavat uusia mahdollisuuksia järjestelmäkehitykseen. Tutkimuksessa kartoitettiin tekoälyn omaksumista yhdessä organisaatiossa ja sen perusteella annetaan ehdotuksia jatkotutkimusaiheiksi.

Asiasanat: tekoäly, koneoppiminen, informaatioteknologia, omaksuminen, organisaatio, TOE, palkanlaskenta

ABSTRACT

Lemmetty, Hanna

Utilising Artificial Intelligence in HR and payroll system

Jyväskylä: University of Jyväskylä, 2020, 83 pp.

Information Systems, Master's Thesis

Supervisor: Seppänen, Ville

Utilising Artificial Intelligence (AI) is gradually increasing in organisations, but there still is insecurity about how well AI is suitable for the business needs and how profitable these investments for AI are. The purpose of the Master's Thesis was to study utilising AI in a HR and payroll system. Utilising AI is reviewed in the perspective of information technology (IT) adoption at the organisational level. The empirical data of the qualitative study was collected by interviewing IT-specialists of the HR and payroll system's development and maintenance teams. The results confirmed suggestions of the previous studies that a lack of AI strategy and competencies needed are recognized as barriers for adopting AI technologies. There is a constant need to adopt new technologies in the IT development, but as results indicated, adoption of AI was not possible in the same way as traditional development methods. AI adoption can be improved with the reasonable resources and with focusing on elevating the competence level in the organisation with training, recruiting or subcontracting. There is already a lot of automation used in HR and payroll systems. However, research indicated that AI technologies can offer new possibilities for system development. Adoption of AI was studied in one organisation and based on that some suggestions for further research are given.

Keywords: artificial intelligence, machine learning, information technology, adoption, organisation, TOE, payroll administration

KUVIOT

KUVIO 1 Tekoälyn taksonomia..... 13

KUVIO 2 TOE-malli..... 24

TAULUKOT

TAULUKKO 1 Informaatioteknologian omaksumisen tutkimuksia..... 26

TAULUKKO 2 Haastateltavien koulutustaso ja ikäryhmä 49

SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT

TAULUKOT

1	JOHDANTO	7
1.1	Tutkimusongelma ja tutkimuksen tavoitteet	8
1.2	Tutkimuskysymykset ja menetelmät niihin vastaamiseen	8
1.3	Tutkielman rakenne.....	10
2	TEKOÄLY.....	11
2.1	Tekoälyn käsitteen määrittelyä.....	11
2.2	Tekoälyn teknologioita.....	13
2.2.1	Tiedonlouhinta.....	14
2.2.2	Koneoppiminen	14
2.2.3	Neuroverkot ja syväoppiminen.....	16
2.2.4	Luonnollisen kielen käsittely ja tekstianalyysi.....	17
2.2.5	Luonnollisen kielen tuottaminen.....	18
2.2.6	Puheentunnistaminen	18
2.2.7	Ohjelmistorobotiikka.....	19
2.3	Tekoäly ja etiikka	19
3	INFORMAATIOTEKNOLOGIAN OMAKSUMINEN	22
3.1	Informaatioteknologian omaksumisen teorioita.....	22
3.2	Informaatioteknologian omaksumisen tutkimuksia ja niissä käytetyt teorat	25
4	TEKOÄLYN OMAKSUMINEN ORGANISAATIOISSA.....	28
4.1	Tekoälyn hyödyntämisen nykytila.....	28
4.2	Tekoälyn omaksuminen teknologian näkökulmasta	29
4.3	Tekoälyn omaksuminen organisaation näkökulmasta.....	30
4.4	Tekoälyn omaksuminen ympäristön näkökulmasta	32
5	TEKOÄLYN HYÖDYNTÄMINEN PALKANLASKENNASSA.....	34
5.1	Palkanlaskentaan vaikuttavia tekijöitä ja teknologioita	34
5.2	Palkanlaskennan tiedot henkilöstöhallinnon ja organisaation päätöksenteon tukena.....	36
5.3	Tekoäly palkanlaskennan poikkeamien havaitsemisessa	38
6	KIRJALLISUUSKATSAUKSEN YHTEENVETO	39

7	EMPIIRISEN TUTKIMUKSEN TOTEUTUS.....	42
7.1	Tutkimuskohde.....	42
7.2	Tutkimusmenetelmän valinta.....	44
7.3	Aineiston kerääminen	45
7.4	Aineiston analyysi	46
8	TUTKIMUSAINEISTON ESITTELY	48
8.1	Taustatiedot.....	48
8.2	Tekoäly ja koneoppiminen käsitteinä	49
8.3	Tekoälyn ja koneoppimisen hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä	50
8.4	Käytettävissä oleva data ja tulevaisuuden datatarpeet	55
8.5	Tekoälyprojektin aloittamisen edellytykset.....	56
8.6	Tekoälyn omaksumisista edistävät tekijät.....	58
8.7	Tekoälyn omaksumisista hidastavat tekijät.....	59
8.8	Tekoälyn hyödyntämisen mahdollisuudet ja riskit	60
9	TUTKIMUSAINEISTON ANALYYSI JA JOHTOPÄÄTÖKSET	63
9.1	Tekoälyn omaksuminen TOE-mallin mukaan	63
9.1.1	Teknologian näkökulma.....	63
9.1.2	Organisaation näkökulma.....	65
9.1.3	Ympäristön näkökulma.....	67
9.2	Tekoälyn teknologioiden hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä	68
9.3	Tutkimuksen merkitys	71
9.4	Tutkimuksen luotettavuus	72
9.5	Tutkimuksen rajoitteet	73
9.6	Jatkotutkimusaiheita.....	73
10	YHTEENVETO.....	75
	LÄHTEET	77
	LIITE 1 TAUSTATIEDOT JA SUOSTUMUS TUTKIMUKSEEN.....	83

1 JOHDANTO

Tekoäly (engl. *Artificial Intelligence*, AI) on ajankohtainen aihe teknologisessa kehityksessä. Eri näkökulmista tarkastellen tekoäly voidaan nähdä kaiken pelastavana teknologiana tai jopa uhkakuvana koko ihmiskunnalle (Brynjolfsson & McAfee, 2012). Tekoäly ei kuitenkaan ole uusi keksintö. Tekoälyn keksijänä pidetään Alan Turingia, joka esitti jo vuonna 1950, että voitaisiin kehittää ihmisaivojen toimintaa jäljittelevä kone (Turing, 1950). Vuosikymmenten kuluessa tekoälyn suurta läpimurtoa on odotettu ennenkin, mutta vasta viimeisen 15 vuoden aikana tekoälyn hyödyntäminen on jatkuvasti lisääntynyt ja saman kehityksen odotetaan jatkuvan (Stone ym., 2016).

Datan hyödyntämisen lisääminen ja dataan perustuva päätöksenteko voivat tuoda yritykselle kilpailuetua. Saman toimialan yritykset, jotka kuuluivat päätöksenteossa eniten dataa hyödyntävien kolmannekseen, olivat keskimäärin 6 % kannattavampia kuin kilpailijansa. (McAfee & Brynjolfsson, 2012.) McKinsey Global Institute (MGI) -tutkimuslaitoksen kansainvälisessä kartoituksessa 47 % yritysjohtajista raportoivat yrityksen hyödyntävän tekoälyä (Chui & Malholtra, 2018). Tekoälyn teknologioihin liittyy silti vielä paljon epävarmuutta ja tiedon puutetta. MGI:n tutkimuksessa 41% vastaajista oli epävarmoja, miten tekoäly soveltuu omaan liiketoimintaan ja tuoko se tuottoja investointiin nähdessä (Bughin ym., 2017).

Pro gradu -tutkielman aihe on tekoälyn hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä. Tekoälyn hyödyntämistä tarkastellaan informaatioteknologian (IT) omaksumisen näkökulmasta. Tutkielman aihe on IT-toimittajalta, joka haluaa saada käsityksen tekoälyn teknologioiden omaksumisesta henkilöstö- ja palkanlaskentajärjestelmän kehityksessä. Teknologisen toimintaympäristön muutos voi merkitä tarvetta strategian muutokseen organisaatiossa. Nopeasti muuttuvassa maailmassa pitkän aikavälin strategioiden suunnitteleminen ja toteuttaminen on vaikeaa. Ulkopuolelta tulevat muutokset vaikuttavat suunnitellun strategian toteutumiseen, koska toimijat sopeuttavat toimiaan ympäröivän maailman kanssa. (Mintzberg & Waters, 1985.) Tekoälyn nousevana teknologisenä trendinä voi vaikuttaa IT-toimittajan järjestelmäkehi-

tyksen strategiaan merkittävästi. Aiemmin hyväksi todetut toiminnot eivät mahdollisesti ole enää riittäviä tulevaisuudessa.

1.1 Tutkimusongelma ja tutkimuksen tavoitteet

Kohdeyritys on pohjoismaiseen ohjelmistoalan konserniin kuuluva talous-, palkka- ja henkilöstöhallinnon ohjelmistotoimittaja, joka toimii asiakkaiden tukena hallinnollisten töiden digitalisoinnissa, automatisoinnissa ja tehostamisessa. Tekoälyn sovelluskenttä on laaja, eikä ole selkeää käsitystä mihin järjestelmän osaan tai toimintoon tekoäly toisi hyötyjä perinteiseen ohjelmistokehitykseen verrattuna. IT-toimittaja haluaa saada käsityksen vaatimuksista, jotka liittyvät tekoälyprojektin aloittamiseen. Pro gradu -tutkielma toimii esiselvityksenä tekoälyn hyödyntämiseen henkilöstö- ja palkanlaskentajärjestelmässä.

Uusien teknologioiden omaksuminen on välttämättömyys IT-alalla, koska aiemmin käytettyjen teknologioiden tilalle tulee tehokkaampia teknologioita. Perinteiseen järjestelmäkehitykseen verrattuna tekoälyn teknologiat ovat erilainen lähestymistapa ongelmanratkaisuun. Tekoälyn omaksuminen liittyy organisaation aineellisiin ja aineettomiin resursseihin. Perinteisesti tietojärjestelmässä tallennetaan tietoja, joita ohjelman käytössä tarvitaan, mutta tekoälyn hyödyntämisessä tiedonhallinnan tarve on erilainen. Tekoälyn osa-alueista koneoppiminen on merkittävässä roolissa tekoälyn sovelluksissa. Koneoppimisen hyödyntämiseen tarvitaan suuria tietomääriä, joilla tekoälyä voidaan opettaa. Tekoälyn soveltaminen vaatii myös henkilöstöltä uusia taitoja ja kyvykkyyksiä. Mielenkiintoista onkin tarkastella, eroaako tekoälyn teknologioiden omaksuminen perinteisen järjestelmäkehityksen teknologioista. Pro gradu -tutkielman aihe on teknologisen kehityksen kannalta ajankohtainen, ja sitä on tutkittu vähän teknologian omaksumisen näkökulmasta. Tekoälyn omaksumista tarkastellaan Tornatzkyn ja Fleicherin (1990) TOE-mallin avulla, joka on kehitetty selittämään teknologisten innovaatioiden omaksumiseen vaikuttavia tekijöitä organisaatioissa.

1.2 Tutkimuskysymykset ja menetelmät niihin vastaamiseen

Tutkimuskysymykset ovat:

”Mitkä tekijät vaikuttavat tekoälyn omaksumiseen organisaatiossa?”

”Miten tekoälyä voidaan hyödyntää henkilöstö- ja palkanlaskentajärjestelmässä?”

Tutkimuskysymyksiin etsitään vastauksia ensin kirjallisuuskatsauksen keinoin. Kirjallisuuskatsauksen tavoitteena on esittää systemaattinen, kokonaisvaltainen ja toistettavissa oleva yhteenveto tutkimusaiheen aiemmasta tutkimuksesta (Okoli & Schabram, 2010). Kirjallisuuskatsauksen lähdemateriaalia haetaan Jyväskylän yliopiston kirjaston sähköisistä tietokannoista: Google Scholar, IEEE Xplore Digital Library ja AIS Electronic Library (AISeL). Google Scholar on monitieteinen tietokanta ja kaksi muuta edellä mainittua ovat IT-painotteisia, jolloin tavoitteena on saada riittävän kattava lähdemateriaali tutkittavasta aiheesta. Vertaisarvioitujen artikkelien käyttäminen lisää työn luotettavuutta. Kirjallisuushakujen aikaväliksi valittiin vuodesta 2000 vuoteen 2019 saakka. Kirjallisuuskatsauksen hakuajan rajaamisella pyritään varmistamaan hakutuloksien kohdentuvan tutkimuskysymysten kannalta olennaiseen ajanjaksoon (Okoli & Schabram, 2010). Tekoälyn pitkässä historiassa voidaan erottaa erilaisia kausia tekoälyn tutkimuksessa ja mahdollisuuksissa hyödyntää tutkimustuloksia käytännön tarpeisiin. Viimeisin tekoälyn hyödyntämisen kausi alkoi n. 15 vuotta sitten, jolloin lähdemateriaalien hakurajaus kattaa reilusti kyseisen ajanjakson. Kirjallisuuskatsauksen hakuja tehtiin tammikuun ja maaliskuun välisenä aikana vuonna 2019.

Tutkimuskysymyksien keskeisimmät käsitteet ovat tekoäly, informaatioteknologian omaksuminen ja palkanlaskenta. Haut tehtiin käyttämällä englanninkielisiä hakusanoja. Hakusanoja käytettiin yhdessä ja erikseen käyttämällä Boolean operaattoreita AND ja OR. Sanojen taivutusmuodot huomioitiin käyttämällä * -merkkiä. Tekoälyyn liittyviä hakuja tehtiin hakusanoilla: "AI", "artificial intelligence", "cognitive computing", "algorithmic intelligence", "machine learning", "ML" ja "data mining". Informaatioteknologian omaksumista haluttiin tarkastella organisaation näkökulmasta, jolloin tarkasteluun otettiin Rogersin (1995) teoria innovaatioiden leviämisestä ja Tornatzky & Fleischerin (1990) TOE-malli. Hakusanoina käytettiin: "IT innovation", "IT adoption", "AI adoption", "AI readiness", "TOE", "diffusion of innovation", "DOI", "innovation diffusion theory" ja "IDT". Palkanlaskentaan liittyvää tutkimusta haettiin sanoilla "payroll", "pay", "payment", "salary" ja "wage". Monitieteisestä Google Scholar -tietokannasta haettiin tekoälyä ja palkkaa kuvaavien hakusanojen yhdistelmillä, mutta haku ei löytänyt julkaisujen otsikoista tutkimuskysymyksiin liittyviä tuloksia. Tästä voidaan päätellä, että aiemmasta tutkimuskirjallisuudessa ei löydy suoraan vastausta tekoälyn hyödyntämiseen palkanlaskentajärjestelmässä. Palkkaa kuvaavilla käsitteillä löydettiin heikosti tutkimuskysymykseen vastaavia julkaisuja ja useammin "pay*" viittasi hakutuloksissa maksetapahtumaan, ei palkkaan. Koska palkanlaskenta on osa henkilöstöhallintoa, hakuja laajennettiin henkilöstöhallintoa ja henkilöstöhallinnon järjestelmiä kuvaaviin hakusanoihin "human resource", "HR", "human resource management", "HRM", "HRMS" ja "HRIS". Hakutuloksina löytyneiden julkaisujen tiivistelmien perusteella arvioitiin julkaisun sopivuutta tutkimuskysymysten kannalta. Tietokantahakujen lisäksi aikaisempaa tutkimusta etsittiin relevanttien julkaisujen lähdeluetteloista lumipallomenetelmällä eteen- ja taaksepäin (Wohlin, 2014).

Kirjallisuuskatsauksen perusteella ei voitu täysin vastata tutkimuskysymyksiin. Tekoälyn omaksumisen tutkimus on vielä ylipäättänsä ollut melko vähäistä ja yksipuolista. Aiemmissa tutkimuksissa on haastateltu yritysjohtajien näkemyksiä tekoälyn hyödyntämisestä, jolloin on mahdollista, että johtajien näkökulma omaksumiseen saattaa olla erilainen kuin henkilöstön näkökulmasta tarkasteltuna. Järjestelmäkehityksen asiantuntijat ovat merkittävässä roolissa uusien IT-tekniologioiden käyttöönotossa, silti tekoälyn omaksumiseen vaikuttavista tekijöistä ei ole tutkittu järjestelmäkehityksen näkökulmasta. Tekoälyn hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä tarvitsee myös lisää tutkimusta.

Kirjallisuuskatsauksen lisäksi tehtiin asiantuntijahaastattelu, jossa haasteltiin optimointi- ja koneoppimisprojektien parissa työskentelevää Joonas Ollilaa Weoptit Oy:stä (Ollila, 2019). Haastattelun tarkoituksena oli saada käytännön tietoa tekoälyprojektien etenemisestä ja haasteista. Koska tutkimuskirjallisuus painottuu ulkomailla tehtyyn tutkimukseen, oli tarve saada myös tietoa tekoälyn hyödyntämisen nykytilasta Suomessa.

Pro gradu -tutkielman empiirisessä osassa täydennetään kirjallisuuskatsauksen osoittamaa tutkimusaukkoa haastattelemalla yhdeksää kohdeyrityksen henkilöstö- ja palkanlaskentajärjestelmän kehitykseen osallistuvaa IT-alan asiantuntijaa. Teemahaastattelujen avulla saatiin järjestelmäkehitykseen osallistuvien henkilöiden näkemys tekijöistä, jotka vaikuttavat edistävästi tekoälyn hyödyntämisen aloittamiseen ja myös tekijöistä, jotka hidastavat omaksumista. Teemahaastatteluissa nousi esiin myös ehdotuksia, miten tekoälyä voitaisiin hyödyntää henkilöstö- ja palkanlaskentajärjestelmässä.

1.3 Tutkielman rakenne

Pro gradu -tutkielma rakentuu seuraavasti. Luku kaksi käsittelee tekoälyn määrittelyä, keskeisimpiä tekoälyn teknologioita ja tekoälyn hyödyntämiseen liittyviä eettisiä näkökulmia. Luvussa kolme tarkastellaan informaatioteknologian omaksumisen teorioita, kuten Rogersin (1995) innovaatioiden diffuusion teoriaa ja Tornatzkyn ja Fleicherin (1990) TOE-mallia, jota on käytetty selittämään IT:n omaksumiseen vaikuttavia tekijöitä organisaatioissa. Samalla tehdään myös yhteenvetoa aiemmin tehdyistä tietojärjestelmätieteen tutkimuksista, joissa on tarkasteltu IT:n omaksumista organisaatiotasolla. Luku neljä käsittelee tekoälyn omaksumista organisaatioissa TOE-mallin mukaisesti teknologian, organisaation ja ympäristön näkökulmista tarkasteltuna. Luvussa viisi tarkastellaan tekoälyn hyödyntämistä palkanlaskennassa. Luvussa kuusi tehdään yhteenveto kirjallisuuskatsauksen vastauksista tutkimuskysymyksiin. Luvussa seitsemän kuvataan empiirisen tutkimuksen toteutus. Luvussa kahdeksan esitellään empiirinen tutkimusaineisto. Luvussa yhdeksän tehdään johtopäätöksiä tutkimusaineistosta ja arvioidaan tutkimuksen hyötyjä, luotettavuutta, rajoitteita ja annetaan ehdotuksia jatkotutkimusaiheiksi. Luku kymmenen on koko tutkielman yhteenveto.

2 TEKOÄLY

Tässä luvussa tarkastellaan tekoälyn laajaa käsitettä yleisellä tasolla ja kuvataan tekoölyyn liitettyjä ominaispiirteitä. Lyhyesti sivutaan myös tekoälyn pitkää historiaa ja käsitellään tekoälyn keskeisiä teknologioita. Luvun lopuksi tarkastellaan tekoälyn hyödyntämiseen liittyviä eettisiä näkökulmia.

2.1 Tekoälyn käsitteen määrittelyä

Digitalisaatiolla tarkoitetaan pitkäaikaista kehitystä, jossa tietotekniikan käyttö yleistyy työelämässä ja vapaa-aikana. Digitalisaation voidaan katsoa alkaneen 1980 -luvulla tietokoneiden yleistyessä työpaikoilla ja kodeissa. 1990 -luvulla Internetin käytön yleistyminen loi uusia mahdollisuudet digitalisaation kehittymiselle. Verkkokauppa, mobiililaitteet, esineiden internet (engl. *Internet of Things*, IOT) ja Big Data ovat esimerkkejä teknologioista, jotka ovat tulleet mahdollisiksi vasta digitalisaation aiempien vaiheiden kehityksen jälkeen. Tekoälyn hyödyntämisen yleistyminen on myös jatkumoa aiempaan digitalisaation kehitykseen. (Alpaydin, 2016.)

Tutkijoita on pitkään kiinnostanut ajatus ihmisaivojen toimintaa jäljittelevästä koneesta. Alan Turing (1950) esitti *Mind*-lehden artikkelissaan kysymyksen: "Voiko kone ajatella?". Tekoälyn havainnollistamiseksi Turing esitti *The Imitation Game* -seuraleikin, jossa on kolme henkilöä, jotka eivät näe toisiaan. Keskellä oleva henkilö yrittää kysymysten avulla selvittää, onko vastaaja mies vai nainen. Kyselevä henkilö ei tiedä, että vastaajan tilalla onkin kone. Asetelma tunnetaan myös Turingin testin nimellä ja testin läpäisy tarkoittaa, että kone osaa jäljitellä ihmisen toimintaa niin hyvin, että konetta luullaan vastausten perusteella ihmiseksi. (Turing, 1950.)

Tekoälyn määrittelemisen ei ole yksiselitteitä. Tekoölyllä tarkoitetaan ihmisen älykkyyteen verrattavissa olevaa keinotekoisia älykkyyttä. Tekoölyllä tarkoitetaan yleensä, että ohjelman tai koneen toimintaa pidettäisiin älykkäänä, jos se olisi ihmisen suorittamaa. Määrittelyn vaikeutta lisää se, että myös ihmi-

sen älykkyyden määrittely ja mittaaminen on vaikeaa. Vallitsee kuitenkin yksimielisyyttä siitä, että tekoälyn määrittely on kannalta olennaista ongelmanratkaisun menetelmä, ei pelkästään ongelman ratkaisu. (Kaplan, 2016.)

Tekoäly voidaan jakaa kapeaan ja yleiseen tekoälyyn (engl. *Narrow and General AI*). Kapea-alainen tekoäly on kehitetty vastaamaan johonkin tiettyyn tarpeeseen, kun taas yleinen tekoäly pyrkii ihmisen älykkyyttä vastaavaan kokonaisvaltaiseen älykkyyteen. (Russell & Norvig, 2016.) Tässä pro gradu -tutkielmassa tarkastellaan ainoastaan kapea-alaista tekoälyä, koska yleinen tekoäly ei ole vielä niin kehittynyttä, että se olisi tällä hetkellä käytettävissä liiketoiminnan tarkoituksiin.

Yleisessä keskustelussa tekoälyllä viitataan usein tietokoneohjelmien tekemisiin monimutkaisiin toimiin, jotka todellisuudessa ovat ohjelmakoodiin kirjoitettua automaatiota. Tekoäly erotetaan tavanomaisesta tietotekniikasta liittämällä tekoälyyn ominaispiirteet itsenäisyys ja mukautuvuus. Itsenäisyys tarkoittaa, että tekoäly toimii ilman käyttäjän jatkuvaa valvontaa ja ohjausta, kuten itseohjautuva auto tai ensimmäinen shakkimestaruuden voittanut IBM:n Deep Blue -tietokoneohjelma. Mukautuvuus tarkoittaa ohjelman muuttumista aiemman toiminnan perusteella. Tätä kutsutaan usein myös oppimiseksi. Tekoäly oppii käyttäjän tekemistä valinnoista ja osaa sen jälkeen mukauttaa toimintaansa aiempien valintojen mukaan, kuten sähköpostin roskapostisuodatus tai aiempien valintojen perusteella ohjelmia suosittelevat suoratoistopalvelut. (Russell & Norvig, 2016.)


Tekoäly ei ole yksittäinen asia, vaan sisältää monia eri tutkimusaloja. Koneoppiminen (engl. *Machine Learning*) on tekoälyn alalaji. Koneoppiminen mahdollistaa mukautuvuuden oppimalla ohjelman aiemmasta käytöstä. Koneoppiminen voidaan jakaa kolmeen eri kategoriaan: ohjattuun, ohjaamattomaan ja vahvistettuun oppimiseen. Keinotekoiset neuroverkot (engl. *Artificial Neural Networks*, ANN) ja syvissä neuroverkoissa tapahtuva syväoppiminen (engl. *Deep Learning*) ovat koneoppimisen alalajeja. Data-analytiikka ja tiedonlouhinta liittyvät läheisesti tekoälyyn ja koneoppimiseen. (Alpaydin, 2016.)

Tekoälyn pitkästä historiasta huolimatta, vasta viimeisen 15 vuoden aikana digitalisaatio on mahdollistanut tekoälyyn liittyvien teorioiden tuomisen käytäntöön. Koneoppimista on tutkittu pitkään, mutta aiemmin sen hyödyntäminen käytännössä on ollut vaikeaa. Internetin käytön myötä kertyy suuria datamassoja, joita tarvitaan koneoppimisessa. Tietokoneiden muistikapasiteetin ja prosessointitehojen kasvaminen mahdollistavat tekoälyn tarvitseman suorituskyvyn. Koneoppimisen mahdollisia sovelluskohteita onkin nähtävissä kaikkialla entistä laajemmin. (Brynjolfsson & McAfee, 2012.)

Yhteenvedon voidaan todeta, että tekoälyn määrittely ei ole yksinkertaista, ja sen teknologiat voidaan jaotella eri tutkimusaloihin. Tekoälyn määrittely ja jaottelu tutkimusaloihin ei ole liiketoiminnan kannalta erityisen merkityksellistä, vaan tärkeämpää on, miten teknologiat ratkaisevat käytännön ongelmia ja tuovat lisäarvoa niiden käyttäjille. Seuraavissa alaluvuissa tarkastellaan tekoälyyn liittyviä teknologioita ensisijaisesti ongelmanratkaisun kannalta.

2.2 Tekoälyn teknologioita

Kuten edellä mainittiin, tekoäly ei ole yksittäinen teknologia, vaan tekoäly on laaja käsite pitäen sisällään monia teknologioita ja niiden yhdistelmiä. Tekoäly on osa tietojenkäsittelytiedettä. Koneoppiminen voidaan luokitella osaksi tekoälyä ja syväoppiminen on osa koneoppimista. Tietojenkäsittelytiede sisältää monia tutkimusaloja, kuten ohjelmistotuotannon, ihmisen ja teknologian välisen vuorovaikutuksen sekä hajautetun laskennan. Datatiede (engl. *Data Science*) käyttää tietojenkäsittelytiedettä, tekoälyä, koneoppimista, tiedonlouhintaa, tilastotiedettä ja näiden lisäksi myös muita tieteenaloja, kuten liiketaloustiedettä, joten datatiedettä pidetään erillisenä tietojenkäsittelytieteestä. (Tekoälyn perusteet, 2019.) Seuraavassa kuviossa esitetään tekoälyn taksonomia (kuvio 1).



KUVIO 1 Tekoälyn taksonomia (Tekoälyn perusteet, 2019).

Seuraavissa alaluvuissa tarkastellaan ensin tiedonlouhintaa, koneoppimista, neuroverkkoja ja syväoppimista. Tekoälyn teknologioissa ongelmanratkaisun lähestymistapa on datalähtöinen. Datalähtöisyyden takia tiedonlouhinta on merkityksellisessä roolissa tekoälyn ja koneoppimisen hyödyntämisessä, vaikka tiedonlouhintaa voidaan tehdä ainakin jossain määrin myös ilman koneoppimistakin. Tässä luvussa käsitellään myös kieleen ja puheeseen liittyvät teknologioita. Ohjelmistorobotiikkaa käsitellään myös lyhyesti, koska se mainitaan usein tekoälyn soveltamisen yhteydessä ja on usein ensimmäinen askel automaation lisäämisessä. Tekoälyn teknologiat sisältävät runsaasti erilaisia menetelmiä, mutta tässä luvussa tarkasteluun on valittu henkilöstö- ja palkanlaskennan tarpeen näkökulmasta ne teknologiat, jotka voisivat tuoda parhaiten hyötyjä tämän hetkisen kehityksen valossa tarkastellen. Tästä syystä esimerkiksi fyysiset robotit on rajattu tarkastelun ulkopuolelle.

2.2.1 Tiedonlouhinta

Datan määrä maailmassa on kasvanut valtavasti viime vuosina. Datalla tarkoitetaan digitaalisesti tallennettua tietoa tai tiedon osaa. Usein vasta useamman datan yhdistelmästä muodostuu tietoa. Internetin käyttö on lisännyt kerätyn datan määrää, koska käyttäjien toimista tallennetaan runsaasti dataa tietokantoihin. Tiedonlouhinnalla (engl. *Data Mining*) tarkoitetaan oleellisen tiedon etsimistä tietotekniikan keinoin suuresta datamäärästä. Suuret organisaatiot ovat jo hyödyntäneet menestyksekkäästi tiedonlouhintaa, mutta silti tietokannoissa on runsaasti dataa, jota ei hyödynnetä. Monet organisaatiot ovat vasta viime vuosina ymmärtäneet oman organisaationsa datan arvon. (Witten ym., 2016.)

Tiedonlouhinta on ongelmanratkaisukeino, jossa etsitään vastauksia analysoimalla olemassa olevaa dataa. Datasta pyritään löytämään toistuvia säännönmukaisuuksia, kaavoja, toimintamalleja ja yhtäläisyyksiä, joista voidaan tehdä luokitteluja ja ennusteita. Tunnettu esimerkki tiedonlouhinnan hyödyntämisestä on asiakastyytyväisyyden ja asiakasuskollisuuden edistäminen. Tunnistamalla suuresta datamäärästä erilaisia asiakasprofiileja voidaan tietoa hyödyntää kohdentamaan asiakasuskollisuutta edistävät toimet oikeisiin asiakkaisiin. Tämä tuo kustannussäästöjä, koska samat toimet koko asiakasjoukkoon kohdistettuina olisivat hyvin kalliita. (Witten ym., 2016.) Tiedonlouhinta on merkittävä teknologia koneoppimisen hyödyntämisessä, koska koneoppimista varten tarvitaan runsaasti dataa. Tiedonlouhintaa ja koneoppimista käytetäänkin usein yhdessä.

2.2.2 Koneoppiminen

Koneoppiminen tarkoittaa, että tietokoneohjelma oppii kokemuksestaan ja pystyy mukauttamaan toimintaansa sen mukaan (Shalev-Shwartz & Ben-David, 2014). Aiemmalla kokemuksella tarkoitetaan järjestelmään tallentunutta dataa, jota käytetään hyödyksi koneoppimisessa. Tietokoneella tehtävään ongelmanratkaisuun tarvitaan algoritmeja. Algoritmit ovat komentojen sarjoja, jotka suorittavat jonkin ohjelmoidun tehtävän. Tavallisesti ohjelmointiin käytetään ohjelmointikieltä, jolla määritellään komentojen sarja tiettyä tehtävää varten. Monimutkaisiin tehtäviin ei ole olemassa valmista algoritmia, kuten ennustamaan verkkokaupan asiakkaan seuraavaa ostosta tai tunnistamaan roskapostia muiden sähköpostien joukosta. Koneoppimisen tarkoituksena on, että algoritmi muodostetaan aiemman datan perusteella oppimisen aikana. Tekoäly-termin lisäksi käytetäänkin myös termiä algoritminen älykkyys (Markus, 2017). Koneoppimista voidaan pitää vaatimuksena tekoälylle, koska muuttuvassa ympäristössä toimivaa järjestelmää ei voida pitää älykkäänä, ellei se opi ja mukaudu ympäristöönsä. (Alpaydin, 2016.) Koneoppimista tarvitaan kahden pääsyyn takia: ongelma on monimutkainen ja sen takia hyvin vaikeasti ohjelmoitavissa tai on tarve, että ohjelma mukautuu kokemuksensa perusteella. (Shalev-Shwartz & Ben-David, 2014.)

Koneoppimisen menetelmiä on hyödynnetty moniin eri tarkoituksiin. Useat ihmisen tekemät tehtävät ovat hyvin monimutkaisia ohjelmoitaviksi kuten puheen tunnistaminen, autolla ajaminen ja kuvien tunnistaminen. Näiden asioiden oppiminen vie aikaa myös ihmisellä, mutta opittuaan ihminen pystyy toimimaan rutiininomaisesti. Koneoppimisen menetelmin digikamerat osaavat tunnistaa kasvot ja laitteita voidaan ohjata puhekomennolla, esimerkiksi Applen Siri (Apple Siri, 2019) tai Amazon Alexa (Amazon Alexa, 2019). Ajoneuvoissa käytetään useita koneoppimisen menetelmin toimivia onnettomuuksia estäviä järjestelmiä. Monimutkaisten toimien ohjelmointi perinteisin ohjelmoinnin keinoin olisi hyvin työlästä, ellei jopa mahdotonta. (Shalev-Shwartz & Ben-David, 2014.)

Toisena ryhmänä vaikeasti ohjelmoitavista asioista voidaan mainita tehtävät, jotka ylittävät ihmisen kognitiiviset kyvyt. Suurten ja monimutkaisten datasisältöjen analysointi olisi ihmisen hahmottamiskyvyille liian vaativaa. Koneoppimisen menetelmin voidaan suuria datamääriä hyödyntää, kuten on tehty esimerkiksi lääketieteen, sähköisen liiketoiminnan tai tähtitieteen aloilla. Koneoppimisen menetelmin hakukoneet oppivat kohdistamaan paremmin hakuja vastaavia tuloksia. Sähköpostiohjelmat oppivat tunnistamaan roskapostin muiden sähköpostien joukosta ja tietoturvaohjelmistot havaitsemaan virukset. Luottokorttiyhtiöt käyttävät koneoppimisen menetelmiä petosten havaitsemiseen. Maailmassa on yhä enemmän digitalisesti taltioitua dataa, jonka määrät ovat liian suuria ihmisen analysoitaviksi. (Shalev-Shwartz & Ben-David, 2014.) Tiedonlouhintaa käsitellään tarkemmin omassa alaluvussa.

Koneoppimisesta hyötyvät myös ohjelmat, joissa tarvitaan mukautumista. Perinteisten tietokoneohjelmien heikkoutena on niiden muuttumattomuus. Monissa ohjelmissa olisi hyödyllistä mukauttaa ohjelman toimintaa käyttäjän aiemman käytön mukaisesti. Koneoppimisen menetelmin ohjelma mukautuu saamaansa syötteeseen, kuten eri kirjoittajien käsinkirjoitetun tekstin muuttaminen konekirjoitukseksi tai puheentunnistusohjelma oppii tunnistamaan erilaisia puhetyylejä. Mukautumista ovat myös ohjelman tekemät suosittelut käyttäjän aiempien valintojen perusteella. (Shalev-Shwartz & Ben-David, 2014.)

Koneoppimisen hyödyntämisessä voidaan erottaa kolme oppimisen pääalaa, jotka ovat ohjattu, ohjaamaton ja vahvistettu oppiminen. Kolme oppimisen muotoa erotellaan palautteen mukaan, jonka avulla oppiminen tapahtuu. (Russell & Norvig, 2016.) Koneoppimisen algoritmit eroavat joko käytetyn matemaattisen mallin, suorituskyvyn arviointikriteeristön valinnan mukaan tai miten parametreja säädellään optimoinnin aikana. Optimoinnilla tarkoitetaan mallin säätämistä toimimaan parhaalla mahdollisella tavalla opetusdatan kanssa. (Alpaydin, 2016.)

Ohjatussa oppimisessa algoritmi muodostaa mallin opetusdatasta, joka sisältää sekä syötteen (engl. *input*) että oikean tuloksen (engl. *output*). Esimerkiksi käytetyn auton hinnan arviointiin vaikuttavat monet tekijät kuten merkki, malli, valmistusvuosi, ajetut kilometrit ja lisävarusteet. Silti täsmälleen samoilla tiedoilla myytyjen autojen hinnoissa voi olla eroa, joten taustalla täytyy olla muitakin hintaan vaikuttavia tekijöitä. Kun opetusdataksi saadaan riittävän

kattava määrä autojen myyntitietoja, voidaan muodostaa yleistettävä malli, jolla voidaan ennustaa myyntiin tulevien autojen hinta tarkemmin. Yleistettävyydellä tarkoitetaan mallin suorituskykyä muun aineiston kuin opetusdatan kanssa. Yleistettävyyys on keskeinen tavoite koneoppimisessa, koska mallin halutaan toimivan muussakin kuin harjoitusympäristössä. Yleistyksen onnistumiseen vaikuttavat valitun matemaattisen mallin soveltuvuus kontekstiinsa, opetusdatan määrä ja mallin parametrien optimoinnin onnistuminen. Ohjaamaton oppiminen eroaa ohjatusta oppimisesta siinä, että opetusmateriaalissa on syötteet, mutta tulokset eivät ole tiedossa. Algoritmia käytetään etsimään datasta säännönmukaisuuksia sekä luokittelemaan ja ryhmittelemään dataa. (Alpaydin, 2016.)

Vahvistetussa oppimisessa oppiminen tapahtuu yrityksen ja erehdyksen kautta positiivisen ja negatiivisen palautteen avulla. Vahvistettua oppimista on käytetty esimerkiksi shakkipelin opettamiseen. Shakkipelissä palaute annetaan pelin lopuksi, jolloin positiivinen palaute shakkipelin voiton jälkeen kertoo tietokoneohjelmalle onnistumisesta. Ohjelmalle ei kerrota, mitkä toimet pelissä olivat onnistuneita. Opetustilanteiden palaute voidaan antaa tiheämminkin, kunhan se yhdistyy tietyn tavoitteen suorittamiseen. Monimutkaisissa opetusympäristöissä yrityksen ja erehdyksen kautta tapahtuva vahvistettu oppiminen voi olla ainoa mahdollisuus opettaa. Ihmisen on vaikea antaa palautetta yksittäisen siirron paremmuudesta, kun siirtomahdollisuuksia on lukemattomia, jolloin yksinkertaisempaa on kertoa ohjelmalle pelin lopuksi, voittiko vai hävisikö ohjelma pelin. (Russell & Norvig, 2016.) Esimerkiksi Go-pelin lukemattomat mahdollisuudet pelinappuloiden sijoitteluun tekisivät ohjatun oppimisen menetelmästä vaikean. Googlen AlphaGo voitti Go-pelin mestaruuden vuonna 2016. Ensin AlphaGo:lle opetettiin parhaiden mestareiden pelityylejä, mutta tarkoitus ei ollut jäljitellä ihmistä, vaan voittaa ihminen pelissä. AlphaGo löysi uusia pelistrategioita pelaamalla tuhansia pelejä itsekseen neuroverkkojen välillä ja vähitellen vahvistetun oppimisen menetelmällä neuroverkot kehittyivät paremmiksi. (Silver ym., 2016.)

2.2.3 Neuroverkot ja syväoppiminen

Keinotekoiset hermoverkot eli neuroverkot pyrkivät jäljittelemään karkealla tasolla päätöksentekoprosessia ihmisen aivojen hermosoluissa eli neuroneissa. Neuronit muodostavat verkkomaisen rakenteen ja välittävät tietoa toisilleen liitoskohtien eli synapsien välityksellä. (Graupe, 2013.) Jokaisella neuronilla on aktivointiarvo ja neuronien välisellä yhteydellä on painoarvo, joka määrittelee neuronin vaikutuksen toiseen neuroniin (Alpaydin, 2016). Neuroverkko oppii annettujen esimerkkien perusteella eli sitä ei suoraan ohjelmoida toimimaan tietyllä tavalla (Graupe, 2013).

Neuroverkkojen tutkimuksen historia ulottuu 1940-luvulle saakka. Ensimmäisen kerran neuroverkkojen periaatteet kuvasivat Warren McCulloch ja Walter Pitts vuonna 1943. Donald Hebbin vuonna 1949 kuvaama algoritmi tunnetaan Hebbin oppimisen lakina. Vuonna 1958 Rosenblatt kuvasi ensimmäisenä

neuroverkkojen keinotekoisien neuronin, perseptrorin, ja odotukset neuroverkkojen soveltamisen mahdollisuuksista olivat korkealla. Kuitenkin vuonna 1969 Minsky ja Papert osoittivat vakavia rajoituksia perseptronin soveltamisessa, ja se aiheutti notkahduksen neuroverkkotutkimuksessa. Myöhemmin havaittiin, että kahden tai useamman kerroksen neuroverkko korjaa aiemmin esitetyt rajoitukset yhden kerroksen neuroverkon toiminnassa, mutta riittävän tehokkaita menetelmiä ei ollut vielä 1960 - 1970 -luvulla. (Graupe, 2013.) Uusi kiinnostus neuroverkkojen tutkimukseen alkoi 1980-luvun puolivälissä, kun keksittiin takaisinvirtausalgoritmi (engl. *backpropagation algorithm*), jolla useamman kerroksen perseptroneja pystyttiin opettamaan. Kyseinen algoritmi on edelleen tärkeä syvien neuroverkkojen oppimismenetelmissä. (Alpaydin, 2016.)

Neuroverkon arkkitehtuuri ja käytetyt algoritmit ovat erilaisia perinteiseen ohjelmointiin verrattuna. Neuroverkkojen algoritmit ovat verrattain yksinkertaisia, mutta niiden avulla voidaan ratkaista matemaattisesti vaikeasti määriteltäviä ongelmia. Neuroverkkojen vahvuutena on itsejärjestelyominaisuus (engl. *self-organizing feature*), jonka avulla neuroverkko voi soveltua ratkaisemaan laajoja ongelmakohteita. Vastaavien ongelmien ratkaisu perinteisillä ohjelmointimenetelmillä vaatisi hyvin monimutkaisia algoritmeja, ja ne toimisivat vain tiettyyn tarkoitukseen sopien. Kolmas eroavaisuus neuroverkoissa ja perinteisessä ohjelmoinnissa liittyy koodin suorittamisjärjestykseen. Neuroverkkojen vahvuutena on toiminnan samanaikaisuus, kun taas perinteinen ohjelmakoodi etenee peräkkäisesti, jolloin yksittäinen virhe voi estää ohjelman suorittamisen loppuun asti. (Graupe, 2013.)

Big Datan ja tehokkaiden tietokoneiden mahdollistamana syvien neuroverkkojen menetelmät ovat olleet viime vuosina runsaan tutkimuksen kohteena. Syväoppimisessa neuroverkkoja opetetaan kerros kerrallaan joko ohjattua tai ohjaamatonta oppimista käyttäen. Syötteenä käytetään raakadataa, josta jokainen kerros oppii edelliseltä kerrokselta, kunnes lopulta ulostulokerroksessa on haluttu tulos. Syväoppimista on hyödynnetty monissa tekoälyteknologioissa kuten puheen- ja kuvantunnistuksessa. (Alpaydin, 2016.)

2.2.4 Luonnollisen kielen käsittely ja tekstianalyysi

Luonnollisen kielen käsittely (engl. *Natural Language Processing*, NLP) on tutkimusala, joka tutkii miten ihmiset ymmärtävät ja käyttävät kieltä. Tavoitteena on saada tietokoneet käyttämään hyödyksi luonnollista kieltä sisältävää tekstiä tai puhetta. Tutkimusala on monitieteinen yhdistäen osaamista tietotekniikasta, lingvistiikasta, matematiikasta, psykologiasta, tekoälystä ja robotiikasta. Luonnollisen kielen ymmärtäminen tarkoituksena on lauserakenteen, merkityksien ja jopa tunnetilojen havaitseminen käyttäen tilastollisia ja koneoppimisen menetelmiä. (Chowdhury, 2003.) Luonnollisen kielen käsittelyä ja tekstianalytiikkaa käytetään moniin erilaisiin tarkoituksiin, kuten virtuaalisiin avustajiin, havaitsemaan petoksia tai tunnistamaan asiakaspalautteista kirjoittajan tunnetila.

Markkinoilla olevia tekstianalytiikan sovelluksilla voidaan tunnistaa käyttäjän kieli muutamasta hakusanasta, jolloin hakutulokset voidaan näyttää oike-

alla kielellä. Nimentunnistus (engl. *Named Entity Recognition*, NER) on tekstianalytiikan teknologia, jonka avulla strukturoimattomasta tekstistä voidaan tunnistaa ennalta sovitut elementit, kuten henkilöt, paikat, tuotteet tai organisaatiot. (Basistech, 2019.)

2.2.5 Luonnollisen kielen tuottaminen

Luonnollisen kielen tuottamisella (engl. *Natural Language Generation*, NLG) tarkoitetaan teknologiaa, jonka avulla saadaan tietokoneen datasta luonnollista ymmärrettävää kieltä. Teknologia on merkittävä ihmisen ja tietokoneen välisen vuorovaikutuksen lisäämisessä. Teknologia osaa luoda ymmärrettävää tekstiä yhdistelemällä eri muodoissa (yleensä ei-kielellisessä muodossa) olevaa dataa. Teknologiaa voidaan käyttää esimerkiksi asiakaspalvelussa luomaan asiakaskirjeitä ja raportteja sekä tekemään yhteenvetoja liiketoimintatiedoista. (Perera & Nand, 2017.) Teknologia on saatavilla lisättäväksi kaupallisiin tuotteisiin esimerkiksi yleisesti käytettyihin liiketoimintatiedon hallintajärjestelmiin (engl. *Business Intelligence*, BI) tai myynnin tukemiseen tarkoitettuihin ohjelmistoihin (Automated Insights, 2019; Narrative Science, 2019.) Osa tuotteista on kehitysaloja, joita voidaan soveltaa erilaisiin tarkoituksiin yrityksissä (Arria, 2019). Isoilla organisaatioilla on ollut myös omia kehitysprojekteja, esimerkiksi Washington Post on kehittänyt oman NLG -moottori Heliographin, jota käytettiin ensimmäisen kerran luomaan uutisia Rion olympialaisista ja myöhemmin luomaan raportteja vaalituloksista (Mullin, 2016). NLG oli aluksi vain osa-alue luonnollisen kielen prosessoinnissa, mutta on vähitellen kasvanut omaksi tutkimusalakseen. (Perera & Nand, 2017). Tutkijat ovat onnistuneet luomaan tekoälyn sovelluksella vakuuttavilta kuulostavia uutisia. Onkin pelätty, että teknologiaa voidaan hyödyntää valeuutisten luonnissa, koska ihmisen ja koneen luomaa tekstiä on vaikea erottaa toisistaan.

2.2.6 Puheentunnistaminen

Puheentunnistamisesta käytetään usein tarkempaa termiä automaattinen puheentunnistaminen (engl. *Automatic Speech Recognition*, ASR). Teknologia muuntaa puheen ensin tekstimuotoon, jonka jälkeen tietokoneohjelmat voivat hyödyntää puhetta. Teknologian päätarkoituksena on mahdollistaa tietokoneen ohjaaminen puheen avulla. Puhe on ihmisten välillä luontainen tapa kommunikoida. Ihmisen ja koneen välisessä vuorovaikutuksessa on puhetta helpompia tapoja ohjata konetta, koska puheen tulkintaan liittyy monia haasteita verrattuna kirjoitettuihin käskyihin tai valintojen tekemiseen hiiren klikkauksilla. Kuitenkin tietyissä tilanteissa puhe on varsin tehokas tapa ohjata tietokonetta. Puheen tunnistamista on kehitetty yli 50 vuoden ajan ja se on ollut tärkeä teknologia esteettömyyden edistämisen kannalta. Edistysaskeleet ASR -teknologiassa ovat lisänneet teknologian houkuttelevuutta useisiin käyttökohteisiin, esimerkiksi laitteiden ohjaamiseen kodeissa tai työpaikoilla, toimistojen saneluohjel-

miin, puheohjattuihin tietokantahakuihin ja puheen kääntämiseen toiselle kielelle. (Radha & Vimala, 2012.)

2.2.7 Ohjelmistorobotiikka

Ohjelmistorobotiikalla (engl. *Robotic Process Automation, RPA*) tarkoitetaan teknologioita, joilla automatisoidaan työvaiheita. Ohjelmistorobotti käyttää tietojärjestelmää ihmisen tavoin käyttöliittymän kautta. Automaation tavoitteena on tehdä työtä ihmisen puolesta. Hyvin usein keskustellaan, mitä ihmisen kannattaa tehdä ja mitkä tehtävät voidaan suorittaa automaatiolla ihmisen puolesta. RPA:n automaatio tapahtuu *ulkoa sisäänpäin* tarkoittaen, että käytettävä tietojärjestelmä pysyy muuttumattomana, mutta järjestelmän käyttöä automatisoidaan. Kun taas perinteisillä ohjelmointitavoilla tehty automaatio toimii *sisältä ulospäin* automaation tapahtuessa tietojärjestelmän sisällä. RPA:n tavoitteena on vähentää työntekijöiden rutiininomaisia tehtäviä, jotka usein toistuessaan kuluttavat suuren osan työajasta. Viimeisten vuosien aikana RPA-tuotteiden kysyntä on kasvanut voimakkaasti ja uusia RPA-toimittajia on tullut. RPA-investointien odotetaan maksavan itsensä nopeasti takaisin. Ohjelmistorobotiikan määrittelyminen tekoälyn teknologioihin on aiheuttanut jonkin verran epätietoisuutta. Vaikka ohjelmistorobotiikalla voidaan automatisoida ja tehostaa toimintoja, alkeellisempien ohjelmistorobotiikan muotojen ei voida katsoa kuuluvan tekoälyn teknologioihin. Näillä tarkoitetaan ohjelmistorobotteja, jotka tunnistavat elementtejä näytöllä, mutta pienikin muutos ohjelmassa voi saada robotin epäkuntoon. Tekoälyn teknologiaksi voidaan määritellä RPA, jossa tekoälyä ja koneoppimisesta hyödynnetään tekemään robotista älykkäämmän ja mukautuvaisemman. (van der Aalst, Bichler & Heinzl, 2018.)

Yhteenvedona tekoälyn eri teknologioista voidaan todeta, että monien teknologioiden tutkimuksen juuret johtavat vuosikymmenten taakse. Teknologioiden kehittämisessä on ollut onnistumisia ja pettymyksiä. Tutkimuksen lisäksi kiinnostavaa on teknologioiden soveltaminen käytännön ongelmien ratkaisuun. Kuten aiemmin kuvattiin, tekoälyn teknologioiden datalähtöisyys algoritmien muodostamisessa poikkeaa perinteisestä ohjelmoinnista. Erilaisen lähestymistavan takia tekoälyn teknologioihin liittyy aiempaa enemmän tarvetta eettisten näkökulmien arvioinnille. Seuraavaksi tarkastellaan tekoälyä ja etiikkaa.

2.3 Tekoäly ja etiikka

Koneoppimisen menetelmät ovat keskeinen osa tekoälyn hyödyntämisessä. Koneoppiminen luo järjestelmäkehitykseen uusia mahdollisuuksia, jos kohde on liian vaativa ohjelmoitavaksi perinteisin menetelmin tai ohjelmaan tarvitaan mukautumista aiemman käytön perusteella. Koneoppimisen hyödyntämisessä tarvitaan dataa ja algoritmeja. Näihin molempiin käsitteisiin liittyy eettisyyteen ja yksityisyyden suojaan liittyviä kysymyksiä, joita tarkastellaan seuraavaksi.

Koneoppimisen menetelmät eroavat perinteisestä ohjelmointimenetelmästä, joiden toiminta on sääntöpohjaisena paremmin tunnettua ja ennakoitavissa. Koneoppimisen hyödyntämisen edellytyksenä on, että saatavilla on riittävästi kohdetta edustavasti kuvaavaa dataa. Datassa esiintyy usein poikkeavuuksia, joten on mahdollista, että järjestelmän tekemät päätökset ovat onnistuneita yleisille tapauksille, mutta järjestelmä toimii huonosti aliedustetuilla tapauksilla. Koneoppimisen algoritmi voi luokitella yksilön tiettyyn ryhmään tai antaa yksilölle koskevan päätöksen, mutta tarkan perustelun saaminen luokittelusta tai päätöksestä voi olla vaikeaa tai jopa mahdotonta. (Alpaydin, 2016.)

Järjestelmiä käytetään päätöksenteon tukena tai tekemään jopa itsenäisiä päätöksiä. On varmistuttava, että järjestelmä tekee sitä mitä odotetaan, eikä se tee mitään, mitä sen ei odoteta tekevän. Algoritmien läpinäkymättömyys asettaa haasteita luotettavuuden arvioimiselle. (Burrell, 2016; Markus, 2017.) Ratkaisuksi on esitetty katselmointikäytäntöjä sekä koodille että järjestelmän tekeville tulkinnoille ja päätöksille. Järjestelmän kehittämisessä ja katselmoinneissa tarvitaan kohdealueen ja tietotekniikan asiantuntijoiden tiivistä yhteistyötä varmistamaan järjestelmän luotettava toiminta. (Burrell, 2016.)

Algoritminen älykkyys ja ihmisälykkyys ovat erilaisia, ja molemmilla älykkyiden lajeilla on omat vahvuutensa ja heikkoutensa. Käyttötarkoitus on otettava huomioon arvioitaessa, miten algoritmista älykkyyttä, ihmisälykkyyttä tai niiden yhdistelmiä hyödynnetään. Arvoista keskustelu ja eettisten näkökulmien tarkastelu on arvioitava tapauskohtaisesti jokaisessa tekoälyn sovelluskohteessa. Algoritminen älykkyys ilman ihmisen mukana oloa, ei sovellu kaikkiin tarkoituksiin, kuten ratkaisemaan oikeuskäsittelyjen päätöksiä. (Burrell, 2016; Holtel, 2016.) Julkisessa päätöksenteossa vaaditaan läpinäkyvyyttä päätösten perusteista, mutta haasteensa avoimuudelle luovat esimerkiksi syviin neuroverkkoihin perustuvat algoritmit, joiden toimintaa voidaan kuvata mustana laatikkona, koska algoritmista ja sen toiminnasta on vaikea muodostaa selkeää käsitystä (Ailisto ym., 2019).

Datan käsittelyyn liittyy myös yksityisyydensuojan ja tietoturvan huomiointi. Euroopan unionin yleinen tietosuoja-asetus (GDPR) antaa säännöt henkilötietojen käsittelyyn (Regulation (EU) 2016/679). Henkilötiedoilla tarkoitetaan tietoja, joista henkilö voidaan suorasti tai epäsuorasti tunnistaa, kuten nimi, henkilötunnus, IP-osoite ja paikannustiedot. Organisaation tulee olla läpinäkyvä datan käsittelyssään. Järjestelmän käyttäjä antaa suostumuksensa, miten ja mihin tarkoitukseen hänen tietojansa kerätään, käsitellään ja säilytetään. Kun kyse on automaattisesta päätöksenteosta tai profiloinnista, on kiinnitettävä erityistä huomiota toiminnan läpinäkyvyyteen. Datan kerääjän tulee myös huolehtia, että tiedot säilytetään turvallisesti, jolloin ne eivät pääse muiden nähtäviksi ilman käyttäjän lupaa. Tietojen ylläpitäjän on ilmoitettava tietomurrosta 72 tunnin kuluessa tietosuojaviranomaisille. Käyttäjällä on myös oikeus saada tietää mitä tietoja hänestä on kerätty. Tietoihin on myös pystyttävä tekemään korjauksia tai ne on voitava poistaa kokonaan. (Alpaydin, 2016; Tankard, 2016.)

Yhteenvedon voidaan todeta, että arvoista keskustelu on tärkeää kaikessa tekoälyn soveltamisessa. Ihmisen ja koneen roolien rajojen ymmärtäminen sekä

läpinäkyvyys tietojenkäsittelyn menetelmistä ja datan käytöstä ovat ensiarvoisen tärkeitä luotettavuuden ylläpitämisessä. Seuraavassa luvussa käsitellään informaatioteknologian omaksumisen teorioita ja esitellään tietojärjestelmätieteen tutkimuksia, joissa kyseisiä teorioita on käytetty.

3 INFORMAATIOTEKNOLOGIAN OMAKSUMINEN

Tässä luvussa tarkastellaan informaatioteknologian (IT) hyväksymistä (engl. *IT acceptance*) ja omaksumista (engl. *IT adoption*) selittäviä teorioita. IT:n hyväksyminen ja omaksuminen ovat keskeinen osa-alue tietojärjestelmätieteen tutkimuksessa. Teknologioiden hyödyt voivat olla organisaatiotasolla suuret, mutta ne toteutuvat vasta, kun teknologia on hyväksytty ja otettu käyttöön (Davis ym., 1989). Tietojärjestelmätieteen tutkimuskirjallisuudessa käytetään teknologian omaksumisen ja teknologisen innovaation omaksumisen käsitteitä samassa merkityksessä kuin IT:n omaksumista. Samalla tavalla myös hyväksymisen ja omaksumisen käsitteiden käyttö ei ole tietojärjestelmätieteessä täysin vakiintunutta, vaan niitä käytetään vaihdellen. Tässä pro gradu -tutkielmassa käytetään IT:n omaksumisen käsitettä kuvaamaan ilmiön kokonaisvaltaisuutta eli hyväksymisen jälkeen informaatioteknologia omaksutaan osaksi organisaation toimintaa.

3.1 Informaatioteknologian omaksumisen teorioita

IT:n omaksumista on pyritty selittämään eri tekijöiden kautta, jotka vaikuttavat teknologian hyväksymiseen ja käytön aloittamiseen tai teknologian hylkäämiseen. Yksi tunnetuimmista teorioista on Davisin (1985) teknologian hyväksymisen malli (engl. *Technology Acceptance Model*, TAM), jossa kaksi päätekijää vaikuttaa teknologian hyväksymiseen: havaittu hyödyllisyys (engl. *perceived usefulness*) ja havaittu helppokäyttöisyys (engl. *perceived ease of use*). Teorian mukaan teknologiasta tehdyt havainnot muodostavat asenteen käyttöä kohtaan ja vaikuttavat lopulliseen päätökseen teknologian käytöstä tai sen hylkäämisestä.

Vuosien kuluessa TAM-teoriaa on kehitetty eteenpäin ja siihen on liitetty uusia tekijöitä selittämään teknologian hyväksymistä. UTAUT (engl. *Unified Theory of Acceptance and Use of Technology*) kuvaa teknologian omaksumista neljän tekijän kautta: odotukset saatavasta hyödystä (engl. *performance expectancy*),

odotukset käytön vaivalloisuudesta (engl. *effort expectancy*), sosiaalinen vaikutus (engl. *social influence*) ja käyttöä helpottavat olosuhteet (engl. *facilitating conditions*) (Venkatesh ym., 2003). Myöhemmin on kehitetty vielä UTAUT2, joka soveltuu selittämään erityisesti vapaa-ajalla tapahtuvaa teknologian hyväksymistä kolmen uuden tekijän avulla: teknologian tuoma mielihyvä (engl. *hedonic motivation*), hinta (engl. *price value*) ja tottumus (engl. *habit*) (Venkatesh, Thong & Xu, 2012).

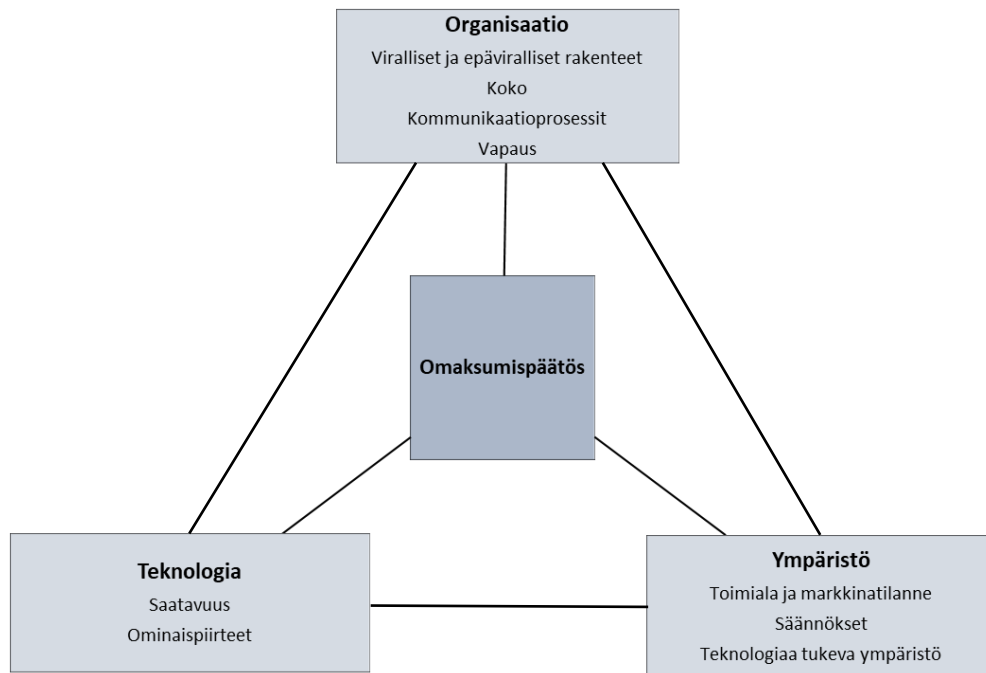
Edellä mainitut teoriat keskittyvät kuvaamaan tilannetta, jossa IT:n hyväksyminen on yksilön päätös. Kuitenkin useimmissa organisaatioissa yksilö ei tee valintaa, vaan päätös teknologian käyttöönotosta tehdään organisaatiotasolla. Organisaatiotason päätöksiin vaikuttavat teknologiasta tehtyjen havaintojen lisäksi monet muutkin tekijät, kuten liiketaloudelliset näkökulmat, kilpailutilanne, organisaation käytössä olevat taloudelliset ja henkiset resurssit sekä yleiset teknologiset trendit. Osa yksilötason teorioista sisältää myös tekijöitä, jotka soveltuvat kuvaamaan organisaatiotasolla tapahtuvaa teknologian omaksumista, kuten UTAUT, johon on lisätty selittäviksi tekijöiksi sosiaalinen vaikutus ja käyttöä helpottavat olosuhteet. Nämä tekijät selittävät organisaatioympäristössä muiden ihmisten vaikutusta ja teknologian käyttöön liittyvän tuen merkitystä teknologian omaksumisessa. Kuitenkin kokonaisuudessaan, yksilötason teoriat eivät huomioi organisaation kannalta merkittäviä tekijöitä, kuten ympäristön vaikutusta, teknologian saatavuutta tai organisaation resursseja. Tietojärjestelmätieteen tutkimuksessa on käytetty organisaatiotasolla tapahtuvan teknologian omaksumisen selittämiseen innovaatioiden diffuusioteoriaa (Rogers, 1995) ja TOE-mallia (Tornatzky & Fleicher, 1990; Oliveira & Martins, 2011).

Rogersin (1995) innovaatioiden leviämisen teoria (engl. *Diffusion of Innovations*, DOI) selittää miten innovaatioista kommunikoidaan ja miten niitä omakсутaan. Innovaatioiden erilainen leviämisenopeus voidaan selittää sillä, miten yksilö kokee innovaation ominaispiirteitä. Havaittuja ominaisuuksia verrataan odotuksiin, ja jos havainnot täyttävät tai ylittävät odotukset, se vaikuttaa positiivisesti innovaation omaksumisnopeuteen. Rogers (1995) jakaa omaksujat viiteen ryhmään innovaation omaksumisnopeuden mukaan: innovaattorit, aikaiset omaksujat, aikainen enemmistö, myöhäinen enemmistö ja hitaat omaksujat. (Rogers, 1995.)

DOI kuvaa innovaation omaksumisen viisivaiheisena prosessina, joka alkaa siitä, kun henkilö saa ensimmäisen kerran tiedon teknologian olemassaolosta. Suostutteluvaiheessa henkilö muodostaa käsitystään teknologiasta tekemällä havaintoja sen hyödyistä ja haitoista. Päätöksentekovaiheessa henkilö päättää joko hyväksyä teknologian tai hylätä sen. Käyttöönottovaiheessa henkilö alkaa käyttämään teknologiaa. Vakiinnuttamisvaiheessa henkilö saa teknologian käytöstä lisää kokemusta ja pyrkii saamaan vahvistuksen teknologian valinnalle. (Rogers, 1995.) Verrattuna teknologian hyväksymisen teorioihin DOI ei selitä ainoastaan teknologian hyväksymistä, vaan vasta käytön ja siitä saadun vahvistuksen kautta tapahtuu teknologian omaksuminen. Hyväksyminen on kuitenkin välttämätön vaihe ennen kuin omaksuminen voi tapahtua.

Vaikka Rogersin (1995) teoriaa on käytetty tietojärjestelmätieteessä yksilöiden IT:n omaksumista kuvaavassa tutkimuksessa, Rogers (1995) on kuvannut teoriassaan myös innovaatioiden omaksumista organisaatiotasolla. Rogersin (1995) mukaan yksilölliset tekijät, organisaatorakenteen sisäiset ominaispiirteet ja organisaation ulkoiset ominaispiirteet ovat tärkeitä ennustamaan innovaation omaksumista organisaatiossa. (Oliveira & Martins, 2011.)

Toinen organisaatiotason omaksumisteoria on teknologian, organisaation ja ympäristön yhdistävä malli (engl. *Technology-Organization-Environment*, TOE), jonka Tornatzky ja Fleicher (1990) esittelivät innovaatioprosesseja kuvaavassa kirjassa (kuvio 2). Mallin mukaan teknologisen innovaation omaksumiseen liittyy organisaatioympäristössä kolme näkökulmaa: teknologian, organisaation ja ympäristön kontekstit. Teknologian näkökulma sisältää sekä yrityksen sisäiset käytössä olevat teknologiat että organisaation ulkopuoliset saatavilla olevat teknologiat. Organisaation näkökulma kuvaa organisaation ominaispiirteitä, kuten kokoa, kommunikaatiota ja hierarkiaa. Ympäristön näkökulma kuvaa organisaation toimintaympäristöä, jossa vaikuttavat toimiala, kilpailutilanne, sidosryhmät, lainsäädäntö ja normit. (Tornatzky & Fleicher, 1990; Oliveira & Martins, 2011.)



KUVIO 2 TOE-malli (mukaiillen Tornatzky & Fleicher, 1990).

TOE-malli on kehittynyt hyvin vähän alkuperäisestä muodostaan. Selitykseksi muuttumattomuuteen on esitetty mallin generisyyttä, jolloin se soveltuu moniin eri sovelluskohteisiin. TOE-mallia käyttäneet tutkijat ovat olleet yksimielisiä mallin kolmesta kontekstista, mutta eri tutkimuksissa kontekstien sisältö ja

painotukset ovat vaihdelleet. (Baker, 2012.) TOE-mallia on käytetty yksinään ja yhdessä DOI:n kanssa. DOI ja TOE ovat muuten samassa linjassa keskenään, mutta TOE-mallissa ympäristön vaikutus teknologian omaksumiseen on esitetty selkeämmin. Ympäristö tuo sekä mahdollisuuksia että vasta-aiheita teknologisen innovaation omaksumiselle. (Oliveira & Martins, 2011.)

TOE-malli on osoittautunut toimivaksi kuvaamaan teknologisten innovaatioiden omaksumista organisaatioissa. Kuitenkin monet teknologiset innovaatiot ovat organisaatioiden välisiä, ei pelkästään yhden organisaation omaksuttavia teknologioita. Iacovou, Benbasat & Dexter (1995) kehittivät mallin, jonka tarkoituksena on kuvata erityisesti organisaatioiden välistä yhteistyötä vaativan teknologian omaksumista, jota muissa malleissa ei ole huomioitu. Malli kehitettiin pienten organisaatioiden välisen sähköisen tiedonsiirron (engl. *Electronic Data Interchange*, EDI) omaksumisen tutkimukseen. EDI-teknologialla tarkoitetaan sähköistä tiedonsiirtojärjestelmää, jossa tieto (esimerkiksi tilaus tai lasku) lähetetään automaattisesti toiseen organisaatioon ja vastaanottajan järjestelmä käsittelee tiedon automaattisesti omassa järjestelmään. Iacovou ym. (1995) mukaan pienten yritysten teknologisen innovaation omaksumiseen vaikuttavat organisaation valmius, ulkopuolelta tulevat paineet teknologian käyttöönottoon ja teknologiasta havaitut hyödyt. (Iacovou ym., 1995.)

3.2 Informaatioteknologian omaksumisen tutkimuksia ja niissä käytetyt teoriat

Seuraavaksi esitellään informaatioteknologian omaksumisen tutkimuksia ja niissä käytettyjä teorioita. TOE-mallia on käytetty monessa IT:n omaksumisen tutkimuksessa tietojärjestelmätieteessä. Thong (1999) käytti TOE-mallia pohjana pienten yritysten tietojärjestelmien omaksumisen tutkimuksessa. Mallia on käytetty myös selittämään EDI-teknologian omaksumista (Kuan & Chau, 2001). Pan ja Jang (2008) selittivät toiminnanohjausjärjestelmän (engl. *Enterprise Resource Planning*, ERP) omaksumista TOE-mallin avulla. Mallia on käytetty myös monessa sähköisen liiketoiminnan omaksumisen (engl. *E-business*) tutkimuksessa (Zhu ym., 2003; Zhu & Kraemer, 2005; Oliveira & Martins, 2010). TOE-mallia on käytetty kuvaamaan organisaatioiden valmiutta digitaalisiin ratkaisuihin (engl. *E-Readiness*) (Aboelmaged, 2014). Meneillään on myös TOE-malliin pohjautuva tutkimus, jonka aiheena on kehittää tekoälyvalmiutta selittävä malli (engl. *AI-Readiness Framework*), joka pyrkii tunnistamaan tekoälyn omaksumiseen vaikuttavia tekijöitä (Alsheibani, Cheung & Messom, 2018).

Kuten edellä esitettiin, useat tutkimukset ovat osoittaneet TOE-mallin toimivaksi kuvaamaan ja selittämään IT:n omaksumista organisaatioissa. Seuraavaksi esitetään kooste tutkimuksista (taulukko 1).

TAULUKKO 1 Informaatioteknologian omaksumisen tutkimuksia.

Tutkija(t)	Nimi	IT	Malli(t)
Iacovou, Benbasat, & Dexter, (1995).	Electronic data interchange and small organizations: adoption and impact of technology.	EDI	Iacovou
Thong, 1999	An integrated model of information systems adoption in small businesses.	IS	DOI, TOE
Kuan & Chau, 2001	A perception-based model for EDI adoption in small businesses using a technology-organization-environment framework.	EDI	TOE
Zhu ym., 2003	Electronic business adoption by European firms: a cross-country assessment of the facilitators and inhibitors.	E-business	TOE
Zhu & Kraemer, 2005	Post-adoption variations in usage and value of e-business by organizations: cross-country evidence from the retail industry.	E-business	TOE
Pan & Jang, 2008	Determinants of the adoption of enterprise resource planning within the technology-organization-environment framework: Taiwan's communications industry.	ERP	TOE
Oliveira & Martins, 2010	Understanding e-business adoption across industries in European countries.	E-business	TOE, Iacovou
Aboelmaged, 2014	Predicting e-readiness at firm-level: An analysis of technological, organizational and environmental (TOE) effects on e-maintenance readiness in manufacturing firms.	E-business	TOE
Alsheibani, Cheung & Messom, 2018 (kesken)	Artificial Intelligence Adoption: AI-readiness at Firm-Level.	AI	DOI, TOE

Tässä pro gradu -tutkielmassa käytetään teoreettisena viitekehyksenä TOE-mallia, koska se huomioi organisaation ympäröivän maailman DOI-teoriaa paremmin. Organisaatio ei toimi tyhjiössä, vaan asiakkaiden odotukset ja kilpailijoiden ratkaisut voivat vaikuttaa tekoälyn omaksumispäätökseen. Ympäristöstä

tuleva paine voi vaikuttaa teknologian omaksumiseen samalla tavalla kuin organisaation sisäiset tekijät tai teknologiasta havaitut hyödyt. Seuraavassa luvussa tarkastellaan tekoälyn omaksumista organisaatioissa TOE-mallin mukaisesti teknologian, organisaation ja ympäristön konteksteissa.

4 TEKOÄLYN OMAKSUMINEN ORGANISAATIOIS- SA

Tekoälyn hyödyntämiseltä odotetaan paljon, mutta ilmiöön liittyy ainakin vielä epävarmuutta ja lunastamattomia lupauksia. Teknologiajätit, kuten Google, Apple ja Amazon, ovat tehneet mittavia sijoituksia tekoälyn soveltamiseen. Pienemmillä organisaatioilla ei ole samoja kehitysresursseja, vaan joudutaan tarkemmin miettimään tekoälyn sovellukseen tehtävää investointia ja arvioitava mahdollisia hyötyjä. Yhteistä organisaatioille kuitenkin on, että tekoälyä nousevana teknologisena trendinä on mahdotonta olla huomioimatta. Organisaatioissa saattaa olla pelkoa teknologisen kehityksen ulkopuolelle jäämisestä, vaikka ei olisi selkeää käsitystä, miten tekoälyä tulisi omassa liiketoiminnassa hyödyntää. Tässä luvussa käsitellään organisaatioiden tekoälyn hyödyntämisen yleisyyttä uusimpien tutkimusten kautta. Tämän lisäksi alaluvuissa tarkastellaan tekoälyn omaksumiseen vaikuttavia tekijöitä TOE-mallin mukaisesti teknologian, organisaation ja ympäristön konteksteissa. Tutkimuksesta etsitään yhdistäviä tekijöitä tekoälyn aikaisille omaksujille ja mitkä seikat ovat olleet esteenä tekoälyn hyödyntämiselle.

4.1 Tekoälyn hyödyntämisen nykytila

McKinsey Global Institute (MGI) kartoitti 3000 yritysjohtajan näkemyksiä tekoälystä kymmenestä eri maasta ja 14 eri sektorilta vuonna 2017. Ainoastaan 20 % vastaajista kertoivat yrityksensä käyttävän jotain tekoälyn sovellusta. (Bughin ym., 2017.) MIT Sloan Management Review esitti samansuuntaisia tuloksia eri alojen yritysten yli 3000 johtotehtävissä työskentelevälle henkilölle vuonna 2017 tehdyn kansainvälisen tutkimuksen pohjalta. Vastaajista 85 % arvioi tekoälyn tuovan yritykselleen kilpailuetua, mutta vain 23 % yrityksistä on ottanut käyttöön jonkin tekoälyn sovelluksen. Vain 5 % yrityksistä oli hyödyntänyt tekoälyn sovelluksia huomattavassa määrin. (Ransbotham ym., 2017.) Tekoälyn hyödyntäminen on kuitenkin lisääntymässä, koska MGI:n vuonna 2018 julkaistussa

kartoituksessa jo 47 % vastaajista raportoi yritystensä hyödyntävän jotakin tekoälyn sovellusta ja 30 % on kokeiluissaan pilotointivaiheessa (Chui & Malhotra, 2018). MIT Sloan Management Review:n tutkimuksessa havaittiin yritysjohtajien korkeat odotukset tekoälyn hyödyntämisen vaikutuksista viiden vuoden kuluessa. Vastaajista 63 % odotti näkevänsä vaikutuksia viiden vuoden kuluessa, mutta tällä hetkellä vain 14 % vastaajista arvioi, että vaikutuksia oli nähtävissä suuresti tai erittäin suuresti. (Ransbotham ym., 2017.)

4.2 Tekoälyn omaksuminen teknologian näkökulmasta

Tekoälyn teknologioihin liittyy vielä paljon epävarmuutta ja tiedon puutetta. MGI:n tutkimuksessa 41 % vastaajista oli epävarmoja, miten tekoäly soveltuu omaan liiketoimintaan ja tuoko se tuottoja investointiin nähden (Bughin ym., 2017). MIT Sloan Management Review:n mukaan yrityksissä oli epätietoisuutta tekoälytuotteen tai palvelun kehittämisen kustannuksista (Ransbotham ym., 2017). Kotimainen raportti julkisen sektorin tekoälysovellusten kokeiluista kuvaa, että kokemusta on pääasiassa vasta virtuaalista avustajista, niin kutsutuista *chatboteista*. Vähäisen kokemuksen takia mitattua tietoa hyödyistä on vielä vähän. Mitatun tiedon sijaan hyötyjen arvioinnissa korostuvat vielä uskomukset ja toiveet tehostamishyödyistä. Investointihyötyjen arviointia vaikeuttaa tekoälypohjaisten ratkaisujen toteutuksen onnistumisen epävarmuus. (Kääriäinen ym., 2018.)

Organisaatiot raportoivat myös puutteellisesta ymmärryksestä tekoälyn hyödyntämiseen tarvittavasta datasta (Ransbotham ym., 2017). Organisaatiossa voidaan tunnistaa arvokkaimmat ja kilpailukyvyn kannalta hyödyllisimmät datan lähteet. Osa datasta voi tulla arvokkaaksi, kun se yhdistetään toisen lähteen datan kanssa. Tekoäly ei ole oikotie, vaan jatkumo sille, että perusta on kunnossa. Tekoälyn hyödyntämisen näkökulmasta onkin tärkeää selvittää, mitä dataa organisaatiossa jo nyt kerätään ja mitä dataa mahdollisesti tarvittaisiin tulevaisuudessa. (Bughin ym., 2017.) Ilman koneoppimisen tarvitsemaa dataa tekoälysovellusta ei voida opettaa. Datan keruu ja aineiston läpikäyminen voi osoittautua työlääksi. Ollila (2019) kertoo haasteista, jotka voivat tulla yllätyksenä koneoppimisen menetelmissä:

Datan keruu voi olla joillekin asiakkaille vähän sellainen shokki, et meidänhän täytyy käydä manuaalisesti tämä koko aineisto läpi. Joidenkin anomalioiden tunnistamistapauksessa poikkeavia havaintoja voi olla sen verran niukasti, että on haastavaa löytää riittävän monta, että siihen voidaan soveltaa jotain koneoppimismallia. (Ollila, 2019.)

Opettaminen voi olla hankalaa myös sovelluskohteen monimuotoisuuden takia. Oulun kaupungin rakennusvalvontaan yritettiin kouluttaa chatbot-asiakaspalvelijaa vastaamaan korjausrakentamiseen liittyvissä kysymyksissä. Kysymysten aihealue rajattiin tarkoituksella pieneen osaan rakennusvalvonnan

toiminnasta, jotta chatbotin kouluttaminen olisi helpompaa. Tästä huolimatta asiantuntijoiden laatimat kysymysten ja vastausten yhdistelmät data-aineistona eivät olleet riittäviä opettamiseen, koska ihmiset voivat kysyä samaa asiaa hyvin eri tavoin. Tässä tapauksessa todettiin paremmaksi, että käyttäjä ei kysy suoraan tekoälysovellukselta, vaan sovellus kysyy ja tarjoaa vaihtoehtoja, joista käyttäjä valitsee. Alkuperäinen ratkaisu korvattiin sääntöpohjaisella päätöspuulla, jossa asiakas valitsee vaihtoehdoista ja päätyy lopulta vastaukseen. (Kääriäinen ym., 2018.)

Tekoälyn hyödyntämiseen tarvittavien työvälineiden käyttöön liittyy myös haasteita. Tiedonlouhintaan käytetään yleisesti avoimen lähdekoodin työvälineitä, joilla voidaan tallentaa, käsitellä ja analysoida suuria määriä dataa. Teknologia ei ole erityisen kallista, vaan useammin pullonkaulaksi muodostuu uusien taitojen puute. (McAfee & Brynjolfsson, 2012.) Data-analyttikkoja tarvitaan suunnittelemaan ja kehittämään tekoälyn sovelluksia. Valmiita tuotteitakin voidaan käyttää, jos ne ovat sopivia tarkoitukseensa. Organisaatioilla on ollut vaikeuksia löytää sopivia tekoälyn sovelluksia, esimerkiksi MGI:n tutkimuksen vastaajista 26 % ei ollut löytänyt tarkoitukseen soveltuvaa tekoälyn sovellusta (Bughin ym., 2017.)

Kuten aiemmin on todettu, organisaatioissa on epävarmuutta tekoälyn soveltuvuudesta omaan liiketoimintaan. Tekoälyyn liittyvän innostuksen myötä saattaa unohtua, että tekoälyn ja koneoppimisen teknologiat ovat ongelmanratkaisukeinoja, joiden toimivuutta täytyy arvioida ongelman näkökulmasta tarkastellen. Ollila (2019) on havainnut, että joskus tekoälyn hyödyntämisessä on menty teknologia edellä ja ongelmaan on yritetty väkisin soveltaa tekoälyn menetelmiä, vaikka se ei ole tilanteeseen sopivin ratkaisu. Tekoälyn soveltaminen kohteisiin, jotka voidaan ratkaista perinteisen data-analytiikan keinoin, ei anna oikeaa kuvaa teknologian hyödyllisyydestä. Ollila (2019) kuvaa erilaisten teknologioiden soveltuvuutta seuraavasti:

Tekoäly tai koneoppimismenetelmät soveltuvat joihinkin tapauksiin, mutta useimmiten parempia tuloksia tai ainakin nopeammin ja halvemmin päästään ratkaisuun sillä, että sovelletaan perinteistä data-analytiikkaa. Organisaatioihin vakiintunut sinänsä terve kokeilukulttuuri ohjaa tekemään pieniä testiprojekteja. Kuitenkin jos data ei ole riittävän hyvässä kunnossa, voidaan pienellä budjetilla todeta tekoälyratkaisusta vain 'ei toimi'. (Ollila, 2019.)

4.3 Tekoälyn omaksuminen organisaation näkökulmasta

Uusien innovaatioiden omaksumisessa on aina ollut aikaisia ja myöhäisiä omaksujia (Rogers, 1995). Havaintojen mukaan tekoälyn aikaiset omaksujat ovat olleet aikaisia omaksujia myös digitaalisen kehityksen aiemmissa vaiheissa, kuten pilvipalveluiden ja Big Datan hyödyntämisessä. Uudemmat teknologiat pohjautuvat aiempiin, joten on luonnollista, että aiempien vaiheiden hyödyntäminen on luonut osaamista, jota voidaan hyödyntää tekoälyn soveltamisessa.

(Bughin ym., 2017.) Käytännössä on nähtävissä myös päinvastaisia etenemistapoja. Organisaatio, jonka toimiala ei varsinaisesti ole digitalisaation eturintamassa, voi silti olla aikainen omaksuja uusissa teknologioissa, jos on nähtävissä selkeä kilpailuetua tuova sovelluskohde, kuten työvoiman tai ajoreittien optimointi (Ollila, 2019). Yhteistä kuitenkin aikaisille omaksujille on se, että tekoälyn soveltaminen liittyy läheisesti yrityksen ydinliiketoimintaan (Bughin ym., 2017).

Vaikka suuret teknologiayritykset ovat olleet aikaisia omaksujia, vaikuttaa siltä, että toimialasta riippumatta suuremmat yritykset ovat olleet aikaisia omaksujia ja pienemmät yritykset ovat tulleet hitaammin mukaan. Sama kehitys on ollut myös digitalisaation aiemmissa vaiheissa. Suuremmat yritykset, joissa työntekijöitä on yli 500, ovat vähintään 10 % todennäköisemmin soveltaneet ainakin yhtä tekoälyn sovellusta kuin pienemmät yritykset. Sektoreilla, joissa tekoälyn hyödyntäminen oli ylipäätänsä vähäistä, ero ison yrityksen ja pienen yrityksen välillä oli 300 %. Suurempien yritysten suuremmalla liikevaihdolla ja kulurakenteella on helpompi saada vastinetta myös tekoölyyn panostamisesta. Aikaiset omaksijat ovat hyödyntäneet tekoälyn sovelluksia laajalaisemmin muihin verrattuna eli on otettu käyttöön useampia tekoälyn sovelluksia. (Bughin ym., 2017.)

MGI:n tutkimuksen vastaajista 43 % nostivat tekoölystrategian puutteen suurimmaksi esteeksi tekoälyn omaksumiseen organisaatiossa (Chui & Malholtra, 2018). Tekoölystrategian tulisi olla samassa linjassa organisaation muun liiketoimintastrategian kanssa. Tekoölystrategia on hyvä suunnitella vähintään viiden vuoden aikavälille. Suunnittelu vaatii ainakin perustietoa tekoälyn mahdollisuuksista ja rajoituksista sekä ymmärryksen siitä, miten tekoälyn hyödyntäminen eroaa perinteisestä järjestelmäkehityksestä. Uhkana on, että tekoölyprojektia lähdetään toteuttamaan liian teknologiavetoisesti unohtaen liiketoimintahyötyjen näkökulman. Tekoälyn sovellusten ollessa vielä useille organisaatioille vaikeasti hahmoteltavissa voidaan tekoälyn strategiassa tavoitella liiankin suuria kokonaisuuksia. Kuitenkin organisaatioille on tarjolla ”matalalla roikkuvia hedelmiä”, jolloin pienemmilläkin kokeiluilla voidaan saada tuloksia aikaan ja oppia kokemuksesta. Tekoälyn soveltaminen sellaisiin liiketoimintamalleihin, joihin on jo olemassa toimiviksi todettuja ratkaisuja, kuten ohjelmistorobotiikka tai koneoppimista hyödyntäviä ohjelmistoja. Pidemmän aikavälin tekoölystrategiaan voidaan ottaa teknologisesta näkökulmasta vielä tällä hetkellä epävarmempia sovelluksia, koska tekoölyteknologiat kehittyvät kuitenkin jatkuvasti. (Bughin ym., 2017.)

MGI:n tutkimukseen vastanneet painottivat yritysjohton tuen merkitystä tekoälyn omaksumisessa. Tekoälyn soveltamisessa tiimityön ja tiimien välisen yhteistyön merkitys organisaatiossa kasvaa. Tekoälyn sovellustavat ylittävät tavanomaisia tiimirajoja, jolloin yhteistyötä tarvitaan eri tiimien välillä. Esimerkiksi tekoölysovelluksella voi olla yhteys asiakaspalveluun, myyntiin, markkinointiin tai raportointiin. (Bughin ym., 2017.) Tekoälyn hyödyntäminen vaatii uudenlaista osaamista, jota ei ole aiemmin tarvittu organisaatiossa. Tekoälyn hyödyntämisen yhdeksi suurimmista esteistä onkin nostettu uusien taitojen

puute (Chui & Malholtra, 2018). Yritysjohdon tuki on tärkeässä roolissa myös työntekijöiden osaamisen kartoittamisessa ja kehittämisessä. Organisaatio voi lisätä osaamista kouluttamalla työntekijöitä tai rekrytoimalla uusia osaajia. Datat ehkäisevät käsittelyn kannalta esimerkiksi NoSQL-tietokantaosaaminen ja Hadoop -teknologioiden tuntemus on arvokasta. Yhteistyö tekoälyyn keskittyneen yrityksen kanssa saattaa myös olla tarpeellista, koska data-analytiikan ja koneoppimisen osaajien rekrytointi ei välttämättä onnistu, koska osaajista on pulaa. (Davenport & Patil, 2012; Bughin ym., 2017.)

Tekoälyn teknologioiden hyödyntäminen vaatii organisaatioilta laaja-alaista osaamista. Ailiston ym. (2019, 49) mukaan tekoäly- ja analytiikkahanke vaatii kolmen seuraavan osaamisalueen yhteen sovittamista: liiketoiminta-, IT- ja analytiikkaosaaminen. Laajojen osaamisalueiden yhdistämisen vaatimuksesta seuraa, että organisaatiot tekevät tekoäly- ja analytiikkakokeiluja, mutta teknologian laajamittainen hyödyntäminen jää vielä usein toteutumatta. (Ailisto ym., 2019.) Tekoälysovelluksiin liittyy epävarmuutta toteutuksen onnistumisesta. Riskien vähentämiseksi voidaan suosia simulaation perustuvaa *proof-of-concept* -lähestymistapaa, jossa tehdään ensin prototyyppi toimivuuden varmistumiseksi, ennen kuin kehitystä viedään laajamittaisesti eteenpäin. Kehitysmenetelmäksi soveltuu ketterä kehitys, jossa nopeissa kehityssykleissä edetään kehittä, testaa ja opi -menetelmällä. (Holtel, 2016.)

4.4 Tekoälyn omaksuminen ympäristön näkökulmasta

Organisaation toimintaan vaikuttaa yrityksen asema toimialan markkinatilanteessa. Kilpailijoiden tekemät ratkaisut tekoälyn hyödyntämisessä voivat vaikuttaa toimialan kilpailutilanteeseen ja myös asiakkaiden mielipiteisiin. MGI:n tutkimuksessa kävi ilmi, että keskeisenä tavoitteena tekoälyn hyödyntämisessä on ollut organisaation kilpailukykyyn edistäminen. Alkuperäisenä tavoitteena on usein ollut kustannusten alentaminen, erityisesti henkilöstökustannusten, mutta saadun kokemuksen myötä suhtautuminen tekoälyn soveltamisen motiiveihin on muuttunut. Kun organisaatiot saivat enemmän kokemusta tekoälystä, säästöjen sijaan tärkeämmäksi tavoitteeksi nousivat kasvun ja kehittämisen mahdollisuudet. (Bughin ym., 2017.)

Organisaation tekoälystrategian luominen ja tarvittavien kehitystoimien aloittaminen varmistaa kehityksessä mukana olemisen, ennen kuin tekoälyn soveltaminen on omalla toimialalla laajamittaista (Bughin ym., 2017). Datat käsittelyn ja koneoppimisen menetelmien osaajista on jo nyt pulaa, joten kilpailu osaajista yritysten kesken voi muuttua aikaa myöten vielä kovemmaksi, jos kiinnostus uusia teknologioita kohden edelleen kasvaa (Davenport & Patil, 2012). Jos tekoälyteknologioiden mahdollisuuksien arviointi jää kokonaan tekemättä organisaatiossa, ei tilannetta ole mahdollista myöhemmin korjata nopeasti, koska tekoälyn hyödyntäminen vaatii pohjatyönsä, jolle menestyvä tekoälysovellus voidaan rakentaa. (Bughin ym., 2017.)

Organisaatioiden toimintaympäristön asenneilmapiiri, tutkimus ja innovaatiot vaikuttavat organisaatioiden tekemiin päätöksiin. Suomen tekoälytutkimus on hyvää kansainvälistä tasoa julkaisuanalyysien ja asiantuntija-arvioiden perusteella. Erityisen korkeatasoista tutkimusta on esimerkiksi konenäön ja laskennallisen data-analyysin tutkimuksessa. Konenäön tutkimus aloitettiin jo 1980-luvulla Oulun yliopistossa. (Ailisto ym., 2019.) Syvien neuroverkkojen tutkimus aloitettiin myös Suomessa jo 1980-luvulla Teuvo Kohosen johdolla (Kohonen, 1982). Suomen vahvuutena pidetään, että tutkimus ei kohdistu pelkästään tekoälyn ydinteknologioihin, vaan korkealaatuista tutkimusta tehdään myös digitaalisista palveluista ja järjestelmätason ratkaisuksista. Erilaista osaamista yhdistävien tutkimusten katsotaan hyödyttävän yrityksiä kilpailukyvyssä luonnissa. Toisaalta Suomen voi olla vaikea kilpailla tutkimuksessa maiden kanssa, joiden resurssit tekoälytutkimukseen ovat huomattavasti suuremmat, kuten Yhdysvallat tai Kiina. Jos tutkimuksen ja organisaatioiden tarpeiden välillä on eroavaisuutta, organisaatiot eivät pysty hyödyntämään olemassa olevaa tutkimusta. Yritysten, tutkimuslaitosten ja yliopistojen tutkimusyhteistyötä tarvitaan jatkossakin varmistamaan organisaatioiden kilpailukykyä. (Ailisto ym., 2019.)

Yksityisyydensuojaan liittyvät kysymykset voivat vaikuttaa organisaatioiden mahdollisuuksiin hyödyntää tekoälyn teknologioita. Kuten aiemmin on todettu, riittävän ja tarkoitukseensa soveltuvan datan saatavuus on ehdoton edellytys tiedonlouhinnan ja koneoppimisen menetelmille. Toukokuussa 2018 voimaan tullut EU:n tietosuoja-asetus (GDPR) on lisännyt organisaatioiden varovaisuutta henkilötietojen käsittelyssä (Regulation (EU) 2016/679). Tämä on luonnollisesti hyvä asia yksilön kannalta, mutta voi vaikeuttaa datan saatavuutta.

Kuten tässä luvussa havaittiin, tekoälyn omaksuminen organisaatioissa on vielä melko vähän tutkittu ilmiö ja useimmat tutkimukset ovat organisaatioiden johdolle tehtyjä kartoituksia. Aiemmissa tutkimuksissa havaittiin, että tekoälyn soveltaminen on ollut vielä melko vähäistä, mutta jo vuoden kuluttua toistetun tutkimuksen mukaan tekoälyä hyödyntävien yritysten määrä oli noussut edelliseen tutkimukseen verrattuna. Tämä viittaisi siihen, että tekoälyn hyödyntäminen on kasvava ilmiö. Seuraavassa luvussa tarkastellaan tekoälyn hyödyntämistä palkanlaskennassa.

5 TEKOÄLYN HYÖDYNTÄMINEN PALKANLASKENNASSA

Palkkahallinto (engl. *Payroll Administration*) on keskeinen osa henkilöstöjohtamista ja henkilöstöhallintoa (engl. *Human Resources*, HR ja *Human Resource Management*, HRM). Palkanlaskentaa tekevän henkilön tehtävänimike on useimmiten palkanlaskija tai palkkasihteeri. Tässä luvussa esitellään tutkimuskirjallisuudesta löytyneitä esimerkkejä tekoälyn hyödyntämisestä palkanlaskentajärjestelmässä. Aluksi käsitellään palkanlaskentaan vaikuttavia tekijöitä ja palkanlaskentajärjestelmiin vaikuttavia teknologioita. Lopuksi tarkastellaan palkanlaskennan tietojen merkitystä henkilöstöhallinnon ja organisaation päätöksenteon näkökulmasta sekä tekoälyn hyödyntämistä palkanlaskennan poikkeamien havaitsemiseen.

5.1 Palkanlaskentaan vaikuttavia tekijöitä ja teknologioita

Palkka liittyy olennaisesti työsuhteeseen. Työnantajan ja työntekijän välisen sopimuksen lisäksi palkan maksuun vaikuttavat lainsäädäntö ja normit. Työehtosopimuksen merkitys on myös keskeinen palkanmaksusta sovittaessa. Tärkeimmät palkanmaksuun vaikuttavat lait ovat ennakonpidätystä ja työntekijöiden lakisääteistä sosiaaliturvaa koskevat säännökset, joista ei voida sopia toisin edes työehtosopimuksella. Normien suhteen noudatetaan etusijajärjestystä, jolloin ristiriitaisessa tilanteessa järjestyksessä etusijalla oleva normi katsotaan määrääväksi toissijaiseen normiin nähden. Tämän lisäksi voidaan käyttää edullisemmuussääntöä, jolloin työntekijän kanssa voidaan sopia työntekijän näkökulmasta edullisempien ehtojen noudattamisesta kuin työlait tai työehtosopimus vaatisivat. (Saarinen ym., 2018.)

Palkka voidaan laskea työhön käytetyn ajan, työn tuloksen tai muun sovitun perusteen mukaan. Muu sovittu peruste voi tarkoittaa esimerkiksi työn vaativuutta, työntekijän koulutusta, kokemusta tai palvelusvuosia. Työntekijän rahapalkka voi olla myös bonus tai palkkio kuten yrityksen tuloksen perusteel-

la maksettu bonus, aloitepalkkio, palvelusvuosipalkkio, merkkipäivän lahjaraha, jouluraha, kokouspalkkio tai muu ylimääräinen kertapalkkio. (Saarinen ym., 2018.)

Työehtosopimusten palkkausjärjestelmät perustuvat pääasiassa työntekijän työtehtävien vaativuuteen sekä työntekijän henkilökohtaiseen suoriutumiseen ja osaamiseen. Henkilökohtaisen suoriutumisen ja osaamisen palkanosan suuruus on määritelty usein tietyinä prosenttiosuutena tehtäväkohtaisen palkan suuruudesta. Kuntasektorin palkat määräytyvät pääsääntöisesti työntekijän tai viranhaltijan tehtävien perusteella. Valtion palkat perustuvat pääosin koko valtionhallintoa koskeviin tai virastokohtaisiin virka- ja työehtosopimuksella sovittuihin palkkajärjestelmiin. (Saarinen ym., 2018.)

Kuten aiemmin todettiin, palkanmaksuun vaikuttavat useat ja ajoittain keskenään ristiriitaiset työlait, normit ja työehtosopimukset, mikä lisää palkanlaskentatehtävien vaativuutta. Vaikka palkanlaskenta on mahdollista kynällä ja paperilla tai taulukkolaskentaohjelman avulla, työ olisi siten tehotonta ja virheeltä. Teknologinen kehittyminen on vaikuttanut viimeisten vuosikymmenten aikana palkanlaskijan tehtäviin. Palkanlaskentajärjestelmien yleistyminen vähensi rutiininomaisten tehtävien määrää. (Danilewicz, 1997.) Palkanlaskentajärjestelmiin on kehitetty automaatiota, joka tehostaa palkanlaskijan työtä merkittävästi. Automaation avulla palkkojen laskenta ja maksaminen suoritetaan käynnistämällä toimintoketjuja, jolloin palkanlaskijan tehtäväksi jää tarkastaa ja korjata virheitilanteet, mutta suuri osa työstä tehdään automaation avulla. Palkanlaskenta voi olla sijoittunut henkilöstöhallinnon näkökulmasta eri tavoin. Palkanlaskennassa voidaan käyttää erillistä järjestelmää tai se voi olla osa henkilöstöhallinnon tietojärjestelmää (engl. *Human Resource Information System*, HRIS tai *Human Resource Management System*, HRMS). Palkanlaskenta voidaan myös kokonaan ulkoistaa organisaation ulkopuolelle. (Tambe, Cappelli & Yakubovich, 2019.)

Huolimatta palkanlaskentajärjestelmiin kehitetystä automaatiosta, palkanlaskennan prosesseihin on silti jäänyt ongelmakohtia, joita palkkahallinnoissa on pyritty tehostamaan ohjelmistorobotiikalla. Ohjelmistorobotiikalla tarkoitetaan tietokoneohjelmaa, joka toimii ihmisen tavoin suorittaen palkanlaskijan tehtäviä. Ohjelmistorobotti on siten yksi palkanlaskentajärjestelmän käyttäjä muiden joukossa. Ohjelmistorobotiikan avulla voidaan tehostaa palkanlaskennan prosesseja. Robotin suorittaessa väsymättä rutiinitehtäviä, työntekijä voi tehdä muita enemmän harkintaa vaativia tehtäviä. (Kääriäinen ym., 2018.) Palkanlaskennan virheettömyyden varmistamiseksi palkanlaskija käyttää runsaasti aikaa palkkojen tarkistamiseen. Robotin tekemät tarkistukset vapauttavat palkanlaskijoiden työaika muuhun työhön. (Hyytiäinen, 2018.) Ohjelmistorobotiikan käytön odotetaan lisääntyvän julkisella sektorilla merkittävästi lähivuosina (Kääriäinen ym., 2018).

Ohjelmistorobotiikka on järjestelmän ulkopuolella kehitettyä automaatiota, jonka vastakkaisena näkökulmana voidaan nähdä järjestelmään ohjelmoitu automaatio. Palkanlaskentajärjestelmän kehityksessä pyritään kehittämään järjestelmää siten, että ohjelmistorobotiikkaa ei tarvittaisi tai sen tarve olisi mahdolli-

simman vähäinen. Ohjelmistorobotiikasta on runsaasti hyötyjä, mutta sen ylläpitäminen vie myös resursseja. Jos palkanlaskentajärjestelmään tulee muutoksia, on mahdollista, että ohjelmistorobotin ohjelma ei enää toimi, ennen kuin se päivitetään vastaamaan uutta versiota. Järjestelmäkehityksen tavoitteena on lisätä palkanlaskentajärjestelmän automaatiota, jolloin monet robotin suorittamat rutiinitehtävät voidaan tehdä ohjelmassa olevalla automaatiolla. (Visma, 2018.)

Digitalisaatio, automaatio ja ohjelmistorobotiikka tarjoavat jo nyt monipuolisia mahdollisuuksia järjestelmäkehitykseen. Vaikka automaatio helpottaa käyttäjien työtä, tekoälyssä nähdään mahdollisuuksia, joihin automaatio ei pysty vastaamaan. Tekoälyyn liitetään ominaispiirteet älykkyys, itsenäisyys, oppiminen ja mukautuminen. Automaatiolla voidaan lisätä järjestelmän itsenäisyyttä ja mukauttamaan toimintaansa käyttäjän valintojen perusteella tiettyyn rajaan asti, mutta tekoälyn vahvuutena on oppiminen ja mukautuminen aiemman käytön perusteella. Kirjallisuuskatsauksen hakuja tehdessä havaittiin, että aiemmasta tutkimuksesta ei saada suoraa vastausta tekoälyn hyödyntämiseen palkanlaskentajärjestelmässä. Palkanlaskentajärjestelmän tiedot kuitenkin mainitaan organisaation arvokkaina tietoina, joita voidaan tekoälyn menetelmin hyödyntää erilaisiin tarkoituksiin. Seuraavissa alaluvuissa tarkastellaan tutkimuskirjallisuuden näkökulmasta palkanlaskennan tietojen käyttöä.

5.2 Palkanlaskennan tiedot henkilöstöhallinnon ja organisaation päätöksenteon tukena

Palkanlaskentajärjestelmän tiedot ovat keskeinen osa henkilöstöhallinnon tietojä. Henkilöstö on organisaation tärkeä resurssi, jonka tiedot, taidot, asenteet ja sitoutuminen vaikuttavat organisaation menestymiseen. HR-datasta voidaan analysoida tietoa, joka on tärkeää organisaation päätöksenteolle ja kilpailuasemalle. Tehdäkseen parempia päätöksiä organisaatioiden on käytettävä kaikki mahdollinen saatavissa oleva tieto, mutta tästä huolimatta HR-datan hyödyntäminen ei ole vielä täysin yleistynyt. Datasta voidaan etsiä hyödyllistä tietoa päätösten tueksi raportointi- ja analyysityövälineillä tai päätöksiä tukevilla järjestelmillä (engl. *Decision Support System, DSS*). (Ranjan, Goyal & Ahson, 2008.)

Henkilöstöjohtamisen ja HR-tietojen merkitys on jo pitkään organisaatioiden tiedossa, joten myös tekoälyltä on jo aiemmin toivottu tukea tähän tehtävään. Tekoälyn tutkimuksen pitkässä historiassa asiantuntijajärjestelmät (engl. *Expert Systems*) olivat ensimmäisiä yleistyneitä tekoälysovelluksia, joiden menestykseltä odotettiin paljon. Asiantuntijajärjestelmien tavoitteena oli sisältää asiantuntijan tietämystä vastaava määrä osaamista ja toimia päätöksenteon apuna vähemmän kokeneille henkilöille. Henkilöstöhallintoon suunnattuja asiantuntijajärjestelmiä kehitettiin esimerkiksi palkkauksen, työsuhde-etujen ja henkilöstöresurssien suunnitteluun. (Lawler & Elliot, 1996.) Asiantuntijajärjestelmien odotettiin parantavan päätösten laatua, mutta vähitellen kiinnostus hiipui, koska järjestelmien valmistaminen ja ylläpito vaativat suuria panostuk-

sia melko vaatimattomiin tuloksiin verrattuna. Sääntöihin perustuvien asian-
tuntijajärjestelmien älykkyys oli kapea-alaista, eivätkä järjestelmät mukautuneet
ympäristönsä mukaan.

Strateginen näkökulma henkilöstöjohtamisessa on yleistynyt 1990-lähtien.
Henkilöstö nähdään resurssina organisaation muiden resurssien kanssa, jolloin
henkilöstöä on arvioitava, kehitettävä ja johdettava systemaattisesti. Data-
analytiikan yleistyessä myös henkilöstöhallinnon data havaittiin merkittäväksi
kiinnostuksen kohteeksi tiedonlouhinnalle. Henkilöstöhallinnon tiedonlouhin-
taa on tutkittu kaikista keskeisistä henkilöstöhallinnon osa-alueista, joita ovat
henkilöstösuunnittelu ja rekrytointi, henkilöstön kehittäminen, työsuoritusten
hallinta sekä palkkaus ja työsuhte-edut. Henkilöstöhallinnon tiedonlouhinta on
muodostanut oman tutkimuskohteensa hallinnon tutkimuksessa. (Strohmeier &
Piazza, 2013.)

Henkilöstöhallinnon data-analytiikan ja tekoälyn hyödyntäminen on vä-
hitellen yleistymässä. Data-analytiikan ja tekoälyn omaksumisen hidastavaksi
tekijäksi on esitetty henkilöstöhallinnon kompleksisuutta, esimerkiksi hyvän
työntekijän ominaisuuksien määrittelemine on vaikeaa. Koneoppimista varten
tarvittavat henkilöstöhallinnon tietomäärät voivat olla verrattain vähäiset. Or-
ganisaatioiden HR-tiedot ovat usein useassa eri järjestelmässä. Rekrytointi,
työntekijöiden osaamisen seuranta, kehityskeskustelut ja palkkatiedot voivat
kaikki olla eri järjestelmissä, jolloin tieto on hyvin hajanaista. Tietojen yhdistä-
minen eri lähteistä voi olla vaikeaa tai jopa mahdotonta, jos ei ole halukkuutta
jakaa tietoja eri järjestelmien kesken. (Tambe ym., 2019.) Datan hyödyntämisen
lisääminen ja dataan perustuva päätöksenteko voivat tuoda yritykselle kilpai-
luetua. Saman toimialan yritykset, jotka kuuluivat päätöksenteossa eniten dataa
hyödyntävien kolmannekseen, olivat keskimäärin 6 % kannattavampia kuin
kilpailijansa. (McAfee & Brynjolfsson, 2012.)

Palkanlaskentajärjestelmä tiedot voidaan nähdä tärkeänä osana organisaat-
ion johtamiseen vaikuttavia tunnuslukuja. Palkanlaskennantietoja voidaan yh-
distää esimerkiksi muihin HR-tietoihin ja voidaan käyttää ennustamaan työ-
voiman tarvetta, henkilöstökuluja ja koulutustarpeita. Palkanlaskennan ulkois-
taminen on yleistä, koska yritykset tavoittelevat kustannussäästöjä ja voivat
käyttää vapautuvia resursseja ydinliiketoimintaansa. Palkanlaskennan ulkois-
tukseen keskittyneet yritykset käsittelevät suuria määriä palkanlaskentaan ja
henkilöstöhallintaan liittyvää tietoa. Eri yritysten palkanlaskentatietoja yhdiste-
lemällä voidaan luoda malleja, joilla voidaan ennustaa henkilöstön tarvetta,
palkkausta tai vaihtuvuutta. Esimerkiksi kansainvälinen yritys ADP, joka tekee
ulkoistettua palkanlaskentaa useille tuhansille yrityksille, on tehnyt ennustavia
malleja henkilöstön palkkauksesta ja vaihtuvuudesta. Asiakkaat ovat luovutta-
neet palkanlaskentatietonsa mallintamisen käyttöön, koska saavat vastineeksi
pääsyn ennustaviin malleihin ja saavat vertailutietoja vastaavista yrityksistä.
(Tambe ym., 2019.)

Tekoälyn hyödyntämisen lisääntyminen organisaatioiden prosesseissa on
luonut pelkoa ihmisen syrjäyttämisestä päätöksen teosta. Kuitenkin tekoälyllä
ja ihmisen älykkyydellä katsotaan olevan omat vahvuutensa, jotka yhdistämällä

voidaan saada yhdistettyä molempien älykkyyden lajien parhaat puolet. Päätöksentekoa vaativat ongelmat ovat usein monimutkaisia ja vaikeasti hahmotettavia. Tekoälyn vahvuutena voidaan pitää monimutkaisuuden analysointia, kun taas ihmisen vahvuutena voidaan pitää asioiden hahmottamista kokonaisvaltaisesti ja intuition käyttöä vaikeasti hahmotettavissa tilanteissa. Ihmisen ja tekoälyn välisen symbioosin uskotaan vahvistuvan tulevaisuudessa organisaatioiden päätöksenteossa (Jarrahi, 2018).

5.3 Tekoäly palkanlaskennan poikkeamien havaitsemisessa

Palkanlaskennan tiedoissa olennaista on aukoton kirjausketju, niin kutsuttu *audit trail*, jonka mukaan palkanlaskentaan vaikuttavan tapahtuman kirjaamisesta voidaan jäljittää koko ketju aina palkanmaksuun asti. Pitkälle automatisoidussa palkanlaskentajärjestelmässä voi olla ohjelmituna poikkeavuuksien havaitsemista, esimerkiksi ohjelma voi ilmoittaa tietyn rajan ylittävistä palkkamääristä ennen palkkojen maksua. Palkanlaskijat voivat myös itse tarkastaa palkkasummia ja verrata niitä aiempiin kuukausiin (Hyytiäinen, 2018). Palkanlaskentajärjestelmän ja palkanlaskijan tekemien tarkastuksien lisäksi kirjallisuudesta löytyy esimerkkejä muista keinoista palkanlaskennan tietojen tarkastamiseksi.

Palkanlaskennan oikeellisuuden varmistamiseen on käytetty liiketoimintatiedon hallinta (engl. *Business Intelligence*, BI) -ratkaisuja ja tietovarastointia (engl. *Data Warehouse*, DW), jolloin palkanlaskennan tiedoista on voitu rakentaa malleja epäsäännöllisyyksien havaitsemiseen (Campos ym., 2012). Tekoälyä on käytetty havaitsemaan poikkeamia palkanlaskennassa ja kirjanpidon tiedoissa. Poikkeamat voivat olla joko tahattomia ohjelmavirheitä tai viitata petokseen. Tekoälysovellus opetetaan tunnistamaan normaalitilanne palkanlaskennan tiedoissa ja havaitsemaan mahdolliset poikkeamat. (Cabral & Oliveira, 2010.)

Yhteenvedona tästä luvusta voidaan todeta, että datasta voidaan löytää tukea päätösten tueksi ja kilpailuedun tavoittelemiseksi. Tekoälyä voidaan käyttää luomaan malleja poikkeamien havaitsemiseksi, mutta myös tehdä ennusteita henkilöstön tarpeesta, palkkauksesta tai vaihtuvuudesta. Markkinoille on tulossa entistä enemmän järjestelmiä päätöksenteon tueksi ja osa päätöksistä voidaan myös automatisoida. Ihmisen ja tekoälyn välisen yhteistyön uskotaan vahvistuvan organisaatioiden päätöksenteossa (Jarrahi, 2018). Ihmisen vahvuutena on kokonaisvaltaisten strategioiden luominen, joiden hahmottaminen ei ole mahdollista yksistään datan perusteella. Strateginen päätös on myös hahmottaa tilanteet, joissa päätöksenteko voidaan automatisoida ja missä tilanteissa ihmisen päätöksenteko on vahvempaa kuin yksistään dataan pohjautuva päätös. (Davenport, 2016.)

6 KIRJALLISUUSKATSAUKSEN YHTEENVETO

Tutkimuskysymyksiin etsittiin vastausta kirjallisuuskatsauksella ja asiantuntijahaastattelulla. Kirjallisuuskatsauksessa tarkasteltiin tekoälyä ja palkanlaskentaa yleisellä tasolla erillisinä ilmiöinä, mutta myös informaatioteknologian omaksumisen teorian ja TOE-mallin kautta yhteisenä ilmiönä. TOE-malli on osoittanut paikkansa teknologisten innovaatioiden omaksumisen teoriana tietojärjestelmätieteen tutkimuksessa. Seuraavissa kappaleissa tehdään yhteenveto kirjallisuuskatsauksen löydöksistä TOE-mallin mukaisesti teknologian, organisaation ja ympäristön näkökulmista. Lopuksi tarkastellaan kirjallisuuskatsauksen merkitystä, luotettavuutta ja jatkotutkimusaiheita.

Teknologian näkökulmasta tarkastellen tekoälyn teknologioiden soveltamiseen liittyy vielä paljon tiedon puutetta ja epävarmuutta toteutuvista hyödyistä. Tekoälyprojektien kustannuksista ei ole vielä riittävästi tietoa, jotta voitaisiin etukäteen arvioida investointien kannattavuutta. Tekoälyn omaksumista on hidastanut organisaatioiden tarpeisiin soveltuvien valmiiden tekoälysovelusten puute. Vaikuttaisi kuitenkin siltä, että tekoälyn hyödyntäminen organisaatioissa olisi lisääntymässä. Tekoälyn hyödyntämiseksi tarvitaan suuria määriä laadukasta dataa. Organisaation datasta voidaan tunnistaa arvokkaimmat ja kilpailukyvyn kannalta hyödyllisimmät lähteet. Osa datasta voi tulla arvokkaaksi, kun se yhdistetään toisen lähteen datan kanssa. Tutkimuksissa havaittiin, että teknologinen kehitys etenee organisaatioissa usein asteittain aiempia digitalisaation teknologioita hyödyntäen. Organisaatiot, jotka ovat olleet ensimmäisten joukossa tekoälyn omaksumisessa, olivat aikaisia omaksujia jo digitalisaation aikaisemmissa vaiheissa. Suurien datamäärien käsittelytaidot ovat merkittävässä roolissa tekoälyn hyödyntämisessä, joten on ymmärrettävää, että aiemmista kokemuksista on hyötyä. Kuitenkin käytännön esimerkit osoittavat, että uusia teknologioita voidaan soveltaa menestyksekkäästi ydinliiketoiminnan prosesseihin organisaation taustasta riippumatta.

Organisaation näkökulmasta tarkastellen organisaation koko on havaittu yhdeksi tekoälyn omaksumiseen vaikuttavaksi tekijäksi. Suuremmilla yrityksillä on paremmat mahdollisuudet panostaa tekoälyyn ja myös sen tuomat hyödyt toteutuvat helpommin suuremmassa mittakaavassa. Tekoälystrategian puute

on nostettu suurimpien esteiden joukkoon tekoälyn omaksumisessa. Samoin suurena ongelmana nähdään uusien teknologioiden hyödyntämiseen tarvittavan osaamisen puute. Data-analytiikan ja tekoälyn teknologioiden osajista on pulaa maailmanlaajuisesti, jolloin tarvittavia osaamisresursseja ei ole helppo rekrytoida. Ylimmän johdon tuki on koettu tärkeäksi tekoälyn teknologioiden omaksumisessa. Tämä on ymmärrettävää, koska ylin johto on avainasemassa tekoälystrategia luomisessa ja osaamisresurssien varmistamisessa.

Ympäristön näkökulmasta tarkastellen tekoälyn omaksumisesta voidaan havaita, että vaikka tekoälystä puhutaan paljon, konkreettisia tekoälyn sovelluksia organisaatioilla on vielä verrattain vähän. Kehityksen ulkopuolelle jäämisen pelko voi lisätä painetta muuttaa organisaation strategiaa. Tekoälyn teknologioiden odotetaan tuovan kilpailuetua kilpailijoihin verrattuna. Tekoälyn hyödyntämisen ensimmäisenä tavoitteena on usein ollut kustannusten alentaminen, mutta tekoälykokeilujen myötä tärkeämmäksi tavoitteeksi nousi kasvun ja kehittämisen mahdollisuudet. Tarvittavan osaamisen varmistamisessa yritysten, tutkimuslaitosten ja yliopistojen yhteistyötä tarvitaan jatkossakin varmistamaan organisaatioiden kilpailukyky. Datan käsittelyyn liittyy myös yksityisyydensuojan ja tietoturvan huomioiminen Euroopan unionin yleinen tietosuoja-asetuksen (GDPR) mukaisesti.

Kirjallisuuskatsauksessa ei löytynyt aiempaa tutkimusta, joka olisi suoraan vastannut kysymykseen tekoälyn hyödyntämisestä henkilöstö- ja palkanlaskentajärjestelmässä. Kuten aiemmissa luvuissa on todettu, tekoäly liittyy läheisesti yleiseen teknologiseen kehitykseen, jonka muita ilmentymiä ovat digitalisaatio, automaatio ja ohjelmistorobotiikka. Palkanlaskentajärjestelmän tiedot ovat keskeinen osa henkilöstöhallinnon tietoja. HR-datasta voidaan tiedonlouhinnan menetelmin saada uutta tietoa henkilöstöhallinnon ja organisaation päätöksenteon tueksi. Datasta voidaan muodostaa esimerkiksi palkkausta ja vaihtuvuutta ennustavia malleja. HR-datan tiedonlouhinnan tutkimusta on tehty kaikista keskeisistä henkilöstöhallinnon osa-alueista. Henkilöstöhallinnon alueella data-analytiikan ja tekoälyn omaksumista hidastaviksi tekijöiksi on esitetty henkilöstöhallinnon kompleksisuutta, riittämättömiä datamääriä ja HR-tietojen hajanaisuutta useissa eri järjestelmissä. Eettisten näkökulmien huomiointi korostuu myös HR-datan kohdalla, erityisesti jos dataa käytetään automaattiseen päätöksentekoon.

Tekoälyä on käytetty myös havaitsemaan poikkeavuuksia suurissa dataaineistoissa. Palkanlaskennan tiedoissa olennaista on aukoton kirjausketju, jonka mukaan palkanlaskentaan vaikuttavan tapahtuman kirjaamisesta voidaan jäljittää koko ketju aina palkanmaksuun asti. Palkanmaksun oikeellisuuden tarkistaminen vie runsaasti palkanlaskijan työaika ja tarkistustavat voivat vaihdella työntekijäkohtaisesti. Tekoälyä onkin käytetty auditoinneissa havaitsemaan poikkeamia palkanlaskennassa ja kirjanpidon tiedoissa.

Kirjallisuuskatsauksesta hyötynee eniten kohdeyritys. Oletettavaa kuitenkin on, että tekoälyn omaksumiseen liittyvät asiat ovat ajankohtaisia monessa muussakin organisaatiossa tällä hetkellä. Kirjallisuuskatsauksen heikkoutena voidaan nähdä palkanlaskennan melko kapea-alainen kohde tekoälyn hyödyn-

tämiseen. Palkkahallinto tai palkanlaskentajärjestelmät eivät ole olleet runsaan tutkimuksen kohteena. Palkkahallinto voi olla myös hyvin eri tavoin sijoittuneena suhteessa henkilöstöhallintoon ja sen järjestelmiin, joten se vaikeuttaa asian tarkastelua tarkemmalla tasolla.

Tekoälyn omaksumiseen vaikuttavista tekijöistä etsittiin vastausta aiemmasta tutkimuksesta. Teknologisten innovaatioiden omaksuminen on keskeinen tutkimusalue tietojärjestelmätieteessä, mutta tekoälyn omaksumisen tutkimus on vasta alkamassa. Tekoälyn omaksumista selittävää teoriaa tarvitaan, jotta organisaatioiden olisi helpompaa aloittaa tekoälyn hyödyntäminen. Viime vuosina monet tutkimuslaitokset, kuten McKinsey Global Institute, MIT Sloan Management Review ja Valtioneuvoston selvitys- ja tutkimustoiminta ovat kartoittaneet tekoälyn hyödyntämistä organisaatioissa. Tutkimuslaitosten tekoälyn omaksumisen tutkimuksiin vastanneet henkilöt olivat organisaatioiden johtajia. Onkin mahdollista, että näkemykset tekoälyn omaksumiseen vaikuttavista tekijöistä eroavat johtajilla ja muulla henkilöstöllä.

Yhteenvetona molempiin tutkimuskysymyksiin voidaan sanoa, että kirjallisuuskatsaus vastasi osittain molempiin kysymyksiin, mutta jätti myös avoimia kysymyksiä. Tarvitaan lisätutkimusta tekijöistä, jotka vaikuttavat tekoälyn omaksumiseen. Vaikka tietojärjestelmätieteessä on tutkittu paljon teknologisten innovaatioiden omaksumista, tarvitaan tutkimusta varmistamaan, pätevätkö samat teoriat myös tekoälyn omaksumiseen vai eroaako sen omaksuminen aiemmista teknologioista. Jatkotutkimusaiheena voisi olla tekoälyn omaksuminen henkilöstön näkökulmasta, koska aiemmissa kartoituksissa vastaajina on ollut organisaatioiden ylin johto. IT-järjestelmien kehitys ja ylläpito on merkittävässä roolissa uusien teknologioiden käyttöönotossa ja omaksumisessa, tästä huolimatta järjestelmän kehitystyöhön osallistuvien asiantuntijoiden näkemyksiä tekoälyn omaksumisesta ei ole tutkittu. Tarvitaan myös lisää tutkimustietoa, miten tekoälyä voidaan hyödyntää henkilöstö- ja palkanlaskentajärjestelmässä. Menestyksekkäästi tekoälyä hyödyntäneet sovellukset vastaavat todelliseen liiketoiminnan tarpeeseen. Ei ole tarkoituksenmukaista käyttää tekoälyä vain sen takia, että se on muodikasta tai kiinnostavaa. Olennaista on tunnistaa liiketoimintahyötyä tuovan tekoälysovelluksen tarve ja liittää se osaksi yrityksen strategiaa.

Kirjallisuuskatsauksen perusteella tunnistettua tutkimusaukkoa täydennetään tässä pro gradu -tutkielmassa tutkimalla henkilöstö- ja palkanlaskentajärjestelmän kehitykseen ja ylläpitoon osallistuvien henkilöiden näkemyksiä tekoälyn omaksumisesta. Tämän lisäksi tutkimuksessa pyritään löytämään mahdollisuuksia hyödyntää tekoälyä henkilöstö- ja palkanlaskentajärjestelmässä. Seuraavassa luvussa kuvataan tutkimuksen toteutus tarkemmin.

7 EMPIIRISEN TUTKIMUKSEN TOTEUTUS

Tässä luvussa kuvataan empiirisen tutkimuksen toteutus ja perustellaan valitut tutkimusmenetelmät. Aluksi kuvataan tutkimuskohde esitellen lyhyesti kohdeorganisaatio ja henkilöstö- ja palkanlaskentajärjestelmä. Seuraavaksi perustellaan tutkimusmenetelmän valinta ja kuvataan aineistonkeruumenetelmä. Lopuksi käsitellään aineiston analyysimenetelmät.

7.1 Tutkimuskohde

Pro gradu -tutkielman empiirisessä osassa tutkitaan henkilöstö- ja palkanlaskentajärjestelmän kehitykseen osallistuvien henkilöiden näkemyksiä tekoälyn omaksumisesta. Tämän lisäksi selvitetään tekoälyn hyödyntämisen mahdollisuuksia henkilöstö- ja palkanlaskentajärjestelmässä. Kohdeyritys on pohjoismaiseen ohjelmistoalan konserniin kuuluva talous-, palkka- ja henkilöstöhallinnon ohjelmistotoimittaja. Tutkimuskohteena ovat järjestelmäkehityksen henkilöt osallistuvat henkilöstö- ja palkanlaskentajärjestelmän suunnittelu-, kehitys-, testaus- ja ylläpitotehtäviin eri rooleissa. Tutkimusasetelman kannalta tärkeässä roolissa on myös henkilöstö- ja palkanlaskentajärjestelmä sekä järjestelmän käyttöön liittyvät palkanlaskentaprosessit, joita molempia kuvataan yleisellä tasolla seuraavaksi.

Henkilöstö- ja palkanlaskentajärjestelmä on Suomessa käytössä oleva ohjelmisto, jota voidaan käyttää palkanlaskentaan kunta-, valtio- ja yrityssektoreilla. Palkanlaskennan tietojen lisäksi järjestelmään voidaan tallentaa henkilöstötietoja. Henkilöstö- ja palkanlaskentajärjestelmässä on kaksi osuutta, joista toinen on tarkoitettu työntekijöiden ja esimiesten käyttöön sekä toinen osuus, jota käyttävät palkanlaskennan ammattilaiset. Henkilöstö- ja palkanlaskentajärjestelmään on kehitetty runsaasti automaatiota, mikä on vaikuttanut palkanlaskijoiden työtehtäviin. Aiemmin palkanlaskijat tallensivat runsaasti itse tietoja järjestelmään, mutta nykyään tietoja tallennetaan eniten siellä missä ne syntyvätkin, esimerkiksi työntekijä ilmoittaa poissaolon tai lomatoiveensa ja esimies hy-

väksyy sen suoraan järjestelmässä. Järjestelmän sääntökerros tekee tarkistuksia ja muuntaa tiedot palkanlaskentajärjestelmän käyttämään muotoon. Tieto poisolosta tai lomasta on siten valmiina palkanlaskentaa varten. Tietoja siirtyy järjestelmään automaattisesti myös toisista järjestelmistä, mikä on myös vähentänyt palkanlaskijoiden tekemää tietojen tallennusta.

Palkanlaskennan vaiheet voidaan jakaa karkealla tasolla kahteen vaiheeseen, joissa ensimmäisen vaiheen aikana uusia tietoja voidaan ilmoittaa vapaasti. Toisessa vaiheessa, palkanmaksupäivän lähestyessä, palkanlaskija käynnistää palkanajoiksi kutsutun vaiheen, jossa palkansaajan tiedot ovat mukana palkanlaskennassa ja uusia meneillään olevaan palkanlaskentaan vaikuttavia tietoja ei voi sillä hetkellä tallentaa. Palkanajot ovat ohjelmia, joita käynnistämällä palkansaajien palkanlaskentatiedot käsitellään ja lopputuloksena valmistuu palkanlaskenta. Ajovaiheita ovat tarkastus-, laskenta-, kirjaus-, tulostus- ja maksumaksajot, joista jokaisella vaiheella on oma tehtävänsä tietojen tarkistamisessa, palkanlaskennassa, kirjanpidossa sekä tietojen välittämisessä pankeille ja muille sidosryhmille.

Automaatiolla on voitu lisätä järjestelmän itsenäisyyttä, jolloin palkanlaskijan ei tarvitse ottaa kantaa kaikkiin järjestelmän tekemiin asioihin. Järjestelmä tekee myös palkanlaskijan puolesta monia työvaiheita, kuten tarkistuksia ja laskutoimituksia. Kun esimies hyväksyy työntekijän järjestelmään tallentaman työsuhteeseen liittyvän tiedon, sääntökerros muuntaa automaattisesti tästä tiedosta tarvittavat palkkatekijät, jotka käsitellään palkanlaskenta-ajossa. Palkanlaskijan ei tarvitse tällaisessa tapauksessa ottaa kantaa järjestelmän toimii. Toisena esimerkkinä voidaan mainita automaatio, joka laskee uudestaan takautuvasti alkavan tiedon vaikutuksen jo maksettuihin palkkoihin. Takautuva laskenta korjaa jo aiemmin maksetut palkat muutospäivästä tähän päivään asti automaattisesti ja säästää palkanlaskijan työaikaa huomattavasti, koska jokaisen palkkaan, verotukseen ja eläkkeeseen vaikuttavan summan laskeminen uudestaan pitkältä ajalta takautuvasti olisi vaativa tehtävä. Kolmantena esimerkkinä automaatiosta voidaan mainita lopputilin laskemiseen kehitetty automatiikkaa, joka helpottaa ja nopeuttaa palkanlaskijan työtä työsuhteiden päättyessä.

Luonnollisesti automaatiot ovat ennalta ohjelmoituja sääntöjä, joiden mukaisesti järjestelmä toimii. Järjestelmä toimii aina samoin annettujen sääntöjen mukaisesti, eikä se opi aiemmista tapahtumista tai mukauta toimintaansa. Ohjelman toiminta on ennakoitavissa, koska tiedossa ovat säännöt, joiden mukaan järjestelmä toimii. Kuten aiemmin on todettu, tekoälyn ongelmanratkaisun lähestymistapa on datalähtöisyydessään erilainen. Tekoälyn sovelluksilla voidaan ratkaista ongelmatilanteita, jotka ovat vaikeasti perinteisillä ohjelmointitavoilla ratkaistavissa. Toisena tarpeena tekoälyn hyödyntämiselle voisi olla tarve ohjelman oppimiselle ja mukautumiselle aiemman käytön perusteella. Näistä lähtökohdista tarkastellen empiirisen tutkimuksen tarkoitus on tutkia järjestelmäkehitykseen osallistuvien henkilöiden näkemyksiä tekoälyn teknologioiden omaksumisesta ja samalla myös selvittää tekoälyn hyödyntämisen mahdollisuuksia henkilöstö- ja palkanlaskentajärjestelmässä.

7.2 Tutkimusmenetelmän valinta

Tutkimusmenetelmän valintaan vaikuttavat tutkittava ilmiö ja tutkimuskysymysten asettelu. Tutkimusmenetelmät jaetaan karkealla tasolla kahteen eri tutkimusmenetelmään: kvalitatiiviseen eli laadulliseen ja kvantitatiiviseen eli määrälliseen tutkimukseen. Kvalitatiivinen tutkimusmenetelmä soveltuu tutkimaan uusia ja monimuotoisia ilmiöitä, joista ei ole vielä riittävästi tutkittua tietoa. Kuten aiemmin on todettu, pro gradu -tutkielman aiheesta ei ole runsaasti aiempaa tutkimusta. Tietojärjestelmätieteen tutkimuksessa kvalitatiivinen tutkimusmenetelmä on yleisesti käytetty, koska se soveltuu ihmisten kokemusten tutkimiseen tietojärjestelmien ja organisaatioiden konteksteissa. Pro gradu -tutkielmassa tarkasteltavassa ilmiössä on kyse informaatioteknologian omaksumisesta ja tutkittavan henkilön näkemyksistä tulevaisuuden kehitystarpeista ja trendeistä. Kvantitatiivisessa tutkimuksessa yleisesti käytetty strukturoitu kysymyslomake valmiine vastausvaihtoehtoineen voisi rajoittaa uusien näkökulmien esiin tulemistä. Kvalitatiivisen tutkimusmenetelmän valinta on perusteltua tuomaan esiin tutkittavan ilmiön eri näkökulmat riittävässä laajuudessa.

Tietojärjestelmätieteen kvalitatiivisessa tutkimuksessa haastattelu on yksi tärkeimmistä aineistonkeruumenetelmistä (Myers & Newman, 2007). Haastattelutyyppien valinnassa on mahdollista valita strukturoidun ja strukturoimattoman haastattelun väliltä. Strukturoidussa haastattelussa kaikki kysymykset ovat ennalta suunniteltuja ja strukturoimaton haastattelu muistuttaa avointa keskustelua. Puolistrukturoitu haastattelu tarkoittaa, että tutkija on valmistellut osan kysymyksistä etukäteen, mutta haastattelussa on jätetty tilaa vapaalle keskustelulle (Myers & Newman, 2007.) Kvalitatiivisessa tutkimuksessa käytetään usein myös teemahaastattelun käsitettä, jolla korostetaan haastatteluteemojen merkitystä yksittäisten kysymysten sijaan. Tässä pro gradu -tutkielmassa käytettiin teemahaastattelua aineistonkeruumenetelmänä. Teemahaastattelussa keskusteltiin kaikkien haastateltavien kanssa etukäteen valituista teemoista. Haastatteluteemoilla varmistettiin, että kaikkien haastateltavien kanssa keskustellaan samoista aiheista, mutta sen lisäksi annettiin tilaisuus tuoda esiin teemojen ulkopuolisia asioita. Teemojen järjestys tai keskustelun pituus yhdestä teemasta saattoi vaihdella haastateltavien välillä. Eri teemoihin liittyviä aiheita käsiteltiin myös muiden teemojen aikana, esimerkiksi tekoälyn hyödyntämiseen liittyviä riskejä saattoi nousta esiin keskusteltaessa mistä teemasta tahansa. Ilman etukäteen tehtyä suunnitelmaa olisi ollut vaarana, että ei saataisi vastauksia tutkimuskysymyksiin tai vastaukset eri haastateltavien välillä jäisivät liian hajanaisiksi, jolloin olisi mahdotonta käsitellä tutkimusaineistoa sisällönanalyysin keinoin.

7.3 Aineiston kerääminen

Kuten johdannossa mainittiin, tutkimuskysymykset ovat ”Mitkä tekijät vaikuttavat tekoälyn omaksumiseen organisaatiossa?” ja ”Miten tekoälyä voidaan hyödyntää henkilöstö- ja palkanlaskentajärjestelmässä?” Haastatteluteemojen valinnassa kiinnitettiin erityistä huomiota siihen, että haastattelut antaisivat vastauksia molempiin tutkimuskysymyksiin.

Haastattelun teemat olivat:

1. tekoäly ja koneoppiminen käsitteinä
2. tekoälyn ja koneoppimisen hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä
3. käytettävissä oleva data ja tulevaisuuden datatarpeet
4. tekoälyprojektin aloittamisen edellytykset
5. tekoälyn omaksumisista edistävät tekijät
6. tekoälyn omaksumista hidastavat tekijät
7. tekoälyn hyödyntämisen mahdollisuudet ja riskit

Haastatteluteemojen järjestyksen tavoitteena oli varmistaa keskustelun luonteva eteneminen teemasta toiseen. Ensimmäinen teema keskittyi tekoälyn ja koneoppimisen käsitteisiin ja niiden merkitykseen haastateltavan näkökulmasta. Tavoitteena oli varmistaa, että haastattelija ja haastateltava ymmärtävät aiheen riittävän samalla tavalla. Aloitus yleisellä tasolla avasi luontevasti keskusteluyhteyden. Toisen teeman tavoitteena oli etsiä vastauksia tutkimuskysymykseen: ”Miten tekoälyä voidaan hyödyntää henkilöstö- ja palkanlaskentajärjestelmässä?” Seuraavat teemat kolmesta seitsemään vastasivat tutkimuskysymykseen: ”Mitkä tekijät vaikuttavat tekoälyn omaksumiseen organisaatiossa?” Kolmas teema keskittyi dataan. Keskustelussa käytiin läpi käytettävissä oleva data, datan keräämisen tarve tulevaisuutta varten ja eri datalähteiden yhdistelymahdollisuuksia. Neljännessä teemassa käsiteltiin tekoälyn hyödyntämisen aloitukseen liittyviä tekijöitä. Haastateltavia pyydettiin miettimään tekoälyprojektin aloitusta ja kertomaan, miten toiminta kannattaisi organisoida, että tekoälyn hyödyntäminen parhaiten onnistuisi. Viidennessä ja kuudennessa teemassa pyrittiin löytämään tekijöitä, jotka vaikuttavat edistävasti tai hidastavasti tekoälyn hyödyntämiseen. Seitsemäs teema käsittelee tekoälyn hyödyntämiseen liittyviä mahdollisuuksia ja riskejä. Tässä teemassa pohdittiin myös kilpailijoiden ja muiden ympäristötekijöiden vaikutusta tekoälyn omaksumiseen.

Henkilöstö- ja palkanlaskentajärjestelmän arkkitehtuuri jakautuu erilaisiin osa-alueisiin, jolloin myös työtehtäviä on jaettu järjestelmän eri toimintakerrosten mukaisesti eri tiimien asiantuntijoille. Esimerkiksi palkanajon suorittavaa järjestelmän osaa kehittävät ja ylläpitävät eri henkilöt kuin käyttöliittymää tekevät tai erillistä sääntökerrosta kehittävät henkilöt. Neljäntenä osa-alueena on

järjestelmätoimitukset sekä kehitys- ja tuotantoympäristön ylläpito. Haastattelujen henkilöiden valinnassa haluttiin varmistaa, että osallistujia olisi kaikista näistä neljästä osa-alueesta. Haastateltavilta tiedusteltiin halukkuutta osallistua tutkimukseen ja sovittiin haastattelu-aika. Tässä vaiheessa henkilöillä oli haastattelun aihe tiedossa, ja heillä oli mahdollisuus ajatella asiaa jo alustavasti etukäteen.

Haastateltavat henkilöt osallistuvat henkilöstö- ja palkanlaskentajärjestelmän suunnittelu-, kehitys-, testaus- ja ylläpitotehtäviin eri rooleissa. Kaikki haastateltavat toimivat asiantuntijatehtävässä ilman esimiesvastuuta. Haastateltavat täyttivät taustatietolomakkeen ja allekirjoittivat tutkimusluvan (liite 1). Taustatietolomakkeella tiedusteltiin haastateltavan ikäryhmä, nimike, koulustausta, tekoälyyn liittyvät kurssit sekä datan käsittelyä tai tekoälyn hyödyntämisestä edistävää osaaminen. Tutkimusluvassa sovittiin haastattelun nauhoittamisesta ja vastausten käytöstä tietojärjestelmätieteen pro gradu -tutkielmassa. Haastateltavat saivat tiedon oikeudestaan keskeyttää tutkimukseen osallistuminen missä vaiheessa tahansa. Haastateltavat olivat tietoisia, että haastattelut ovat luottamuksellisia, eikä yksittäisien vastaajan tietoja voida erottaa tutkielmasta. Tästä syystä haastatteluvastauksia ei kuvailta iän, nimikkeen tai muun henkilöllisyyttä paljastavan tekijän kautta.

Teemahaastattelut tehtiin yksilöhaastatteluina huhti-toukokuun aikana vuonna 2019. Haastatteluja oli yhteensä yhdeksän, joista kahdeksan oli kasvotusten tapahtuneita haastatteluja organisaation neuvotteluhuoneessa. Yksi haastattelu pidettiin Google Meet -etäneuvottelun avulla, koska tapaamisaikaa ei saatu sovittelua haastattelujen suunnitellulle ajanjaksolle. Haastattelut pidettiin 15.4.2019 - 9.5.2019 välisenä aikana, jolloin lyhyehköllä aikavälillä halutaan varmistaa, että organisaation tilanne on kaikkien haastattelujen aikaan suhteellisen samanlainen. Haastattelujen jakautuminen pitkälle aikavälille olisi voinut vaikuttaa vastauksiin. Lyhin haastattelu kesti 36 minuuttia ja pisin 59 minuuttia. Haastattelujen pituuden keskiarvo oli 44 minuuttia. Haastattelut nauhoitettiin matkapuhelimen saneluohjelmalla.

7.4 Aineiston analyysi

Tutkimusmenetelmän valinnassa korostui tutkittavan ilmiön moninaisuus ja tarve saada esiin uutta tietoa. Kvalitatiivisessa tutkimuksessa pyritään ilmiön ymmärtävään selittämiseen, jota tehdään viittaamalla muuhun tutkimukseen ja teoreettiseen viitekehykseen (Alasuutari, 2011). Dey (2005) kuvaa kvalitatiivisen aineiston sisällönanalyysia kolmivaiheisena prosessina alkaen aineiston kuvailemisesta, luokitteluun ja luokittelujen yhdistämiseen. Aluksi teemahaastatteluilla kerätty aineisto litteroitiin. Litteroinnit luettiin useaan kertaan, jotta saatiin kokonaiskäsitys kaikista haastatteluista. Haastatteluista kertyi suuri määrä tekstiä, josta täytyi löytää tutkimuksen kannalta olennaisin tieto. Kvalitatiivisessa sisällönanalyysissa tutkimusaineiston raakadataa yhdistellään ja pyritään havaintojen pelkistämiseen koko aineistoa koskevien olennaisten yhtäläisyyk-

sien havaitsemiseksi (Alasuutari, 2011). Haastattelujen raakadatan käsittelyn helpottamiseksi suositellaan aineiston luokittelua ja koodaamaan sisältöjä suuremmiksi kokonaisuuksiksi (Chi, 1997). Haastattelutekstistä merkittiin eri väreillä kohdat, jotka viittaavat johonkin haastatteluteemaan. Värikoodien mukaan havainnot kerättiin yhteen, jolloin saatiin kokonaiskäsitys kaikkien haastateltavien näkemyksistä haastatteluteemoihin. Luokittelu teemoittain auttoi näkemään samankaltaisuuksia ja eroavaisuuksia haastateltavien vastauksissa, mitä olisi ollut muulla tavoin vaikea erottaa suuresta tekstimäärästä. Viimeisessä analyysivaiheessa teemoittain luokiteltu aineisto yhdistellään TOE-mallin mukaisesti teknologian, organisaation ja ympäristön konteksteihin.

Yksittäisten havaintojen tiivistäminen suuremmiksi kokonaisuuksiksi on sisällönanalyysin päämenetelmä. Suurempien kokonaisuuksien yhdistelemisen lisäksi voidaan aineistosta nostaa esiin yksittäisiä havaintoja ja käyttää niitä johtolankoina sisällön ymmärtämiseen. Yksittäisten haastatteluvastausten sitaatit toimivat tällaisina johtolankoina, joten yksittäistäkin havaintoa voidaan käyttää tulkintojen vahvistamiseen. (Alasuutari, 2011.)

Seuraavassa luvussa kahdeksan tutkimusaineisto esitellään jaoteltuna haastatteluteemojen mukaan. Haastatteluvastausten sitaatteja käytetään johtolankoina aineiston ymmärtämiseen ja tulkintaan. Luvussa yhdeksän tutkimustuloksia analysoidaan tarkemmin aiemman tutkimuskirjallisuuteen verraten ja tehdään tutkimusaineistosta johtopäätöksiä TOE-mallin mukaisesti jaoteltuna.

8 TUTKIMUSAINEISTON ESITTELY

Tässä luvussa esitellään pro gradu -tutkielman empiirisen osan tutkimusaineisto. Aineiston muodostavat lomakkeella kysytyt taustatiedot ja teemahaastattelujen tutkimusaineisto. Luvun alussa kuvataan tutkimukseen osallistuneiden henkilöiden taustatiedot. Taustatietojen jälkeen käsitellään teemahaastattelujen tutkimusaineisto jaoteltuna edellisessä luvussa kuvattujen haastatteluteemojen mukaisesti.

8.1 Taustatiedot

Haastateltavat saivat täytettäväksi lomakkeet, joilla kartoitettiin taustatietoja (liite 1). Osa haastateltavista oli täyttänyt lomakkeen jo ennen haastattelua ja osa täytti lomakkeen haastattelun alussa. Taustatietolomakkeella tiedusteltiin haastateltavan ikäryhmää, nimikettä, koulutustaustaa, tekoälyyn liittyvää koulutusta sekä datan käsittelyä tai tekoälyn hyödyntämistä edistävää osaamista. Haastateltavien ikää tiedusteltiin ikäryhmittäin, koska tarkkaa ikää ei pidetty kovin merkittävänä tulosten kannalta. Haastateltavat henkilöt jakautuvat seuraaviin ikäryhmiin: 26–35, 36–45, 46–55 ja 56–65 vuotta, joka osoittaa, että haastattelut eivät rajoitu yksittäiseen ikäryhmään, vaan eri ikäisten työntekijöiden näkemykset huomioidaan. Haastateltavien vastaukset koulutustasosta osuivat johonkin seuraavista vaihtoehdoista: toisen asteen koulutus, alempi korkeakoulututkinto tai ylempi korkeakoulututkinto. Koulutusalat suuntautuvat kaupalliselle alalle, tietojenkäsittelyyn ja tietotekniikkaan. Haastateltavien työtehtävät liittyvät henkilöstö- ja palkanlaskentajärjestelmän tuotekehitykseen sisältäen eri henkilöillä eri järjestelmäkehityksen osa-alueita, kuten järjestelmän määrittely, kehitys, testaus, toimitus tai ylläpito. Eri osa-alueiden huomioimisella pyritään saamaan riittävän laaja näkemys tekoälyn hyödyntämisestä henkilöstö- ja palkanlaskentajärjestelmässä.

Seuraavassa taulukossa esitetään haastateltavien koulutustaso ja ikäryhmä (taulukko 2).

TAULUKKO 2 Haastateltavien koulutustaso ja ikäryhmä.

Koulutustaso ja ikäryhmä	< 25	26-35	36-45	46-55	56-65	> 65
Toinen aste				1	1	
Alempi korkeakoulututkinto		2	1	1		
Ylempi korkeakoulututkinto		2		1		

Tekoälyyn liittyvien koulutusten määrä vaihteli haastateltavien välillä. Viisi vastaajaa ilmoitti, että ei ole osallistunut tekoälyyn liittyviin koulutuksiin. Neljä vastaajaa on suorittanut joko osittain tai kokonaan tekoälyyn liittyviä verkkokursseja, kuten Helsingin yliopiston kaikille avoin kurssi *Elements of AI* ja Ude-my-verkkokoulutusalan tarjoamia tekoälyn teknologioita käsitteleviä kursseja. Haastateltavilla on monia taitoja ja osaamisalueita, joista on hyötyä tekoälyn tai koneoppimisen hyödyntämisessä. Suurin osa haastateltavista tekee kehitystyötä, jolloin ohjelmointitaidot ja tietokantaosaaminen luovat jo ainakin alustavan perustan datan käsittelyn ja koneoppimisen hyödyntämiselle. Kaikilla haastateltavilla on ohjelmointikokemusta, vaikka ohjelmointi ei kaikilla kuulu nykyisiin työtehtäviin. Tekoälyn hyödyntämisen näkökulmasta tärkeänä voidaan pitää myös sovelluskohteen tuntemusta, kuten HRM-substanssiosaamista, henkilöstö- ja palkanlaskentajärjestelmän tuntemusta sekä pitkää yhteistyötä asiakkaiden kanssa.

8.2 Tekoäly ja koneoppiminen käsitteinä

Teemahaastattelu aloitettiin tekoälyn ja koneoppimisen käsitteillä. Haastateltavat saivat omin sanoin kuvailla, mitä tekoäly heille tarkoittaa. Useat haastateltavat tunnistivat arkipäiväisiä asioita, joiden taustalla käytetään jotakin tekoälyn sovellusta, kuten selainten hakukoneet tai mobiililaitteen puheella ohjattava avustaja. Haastateltavien kanssa käsiteltiin tekoälyn ominaispiirteitä, kuten oppiminen, mukautuminen ja itsenäisyys. Tekoäly on hyvin laaja käsite, ja sen takia haastattelun aloittavan teeman tarkoituksena oli varmistua, että haastateltaja ja haastateltava ymmärtävät tekoälyn riittävän samalla tavalla.

Haastateltavien kanssa käytiin läpi tekoälyn määritelmiä, kuten jo Turingin (1950) esittämää pohdintaa koneen älykkyyden määrittelemisestä – jos ihmisen toimintaa pidetään älykkäänä, voidaanko silloin myös samalla tavalla toimivaa konetta pitää älykkäänä. Tekoälyn ja koneoppimisen ominaispiirteistä

haastateltavat mainitsivat useimmiten oppimisen. Ominaispiirteinä mainittiin myös suurten datamassojen käsittely ja itsenäisten päätösten tekeminen datan perusteella. Useat haastateltavat ajattelivat asiaa myös päinvastaisesti tunnistaen tekijöitä, jotka eivät ole tekoälyä, kuten sääntöihin perustuva ohjelmakoodi, vaikka ohjelma toimisi hyvinkin älykkäästi. Haastateltavien kanssa keskusteltiin myös näkemyksestä, onko tekoälyn ominaispiirteitä nähtävissä henkilöstö- ja palkanlaskentajärjestelmässä tällä hetkellä. Järjestelmässä ei ole tekoälyä, mutta automaation avulla järjestelmän toiminta on älykstä ja ajoittain itsenäistäkin, mutta järjestelmä ei opi tai muokkaa toimintaansa aiemman käytön ja siitä syntyvän datan pohjalta.

IT-alan koulutuksesta ja kokemuksesta huolimatta tekoälyn käsite koettiin laajaksi ja vaikeasti määriteltäväksi. Keskustelussa käytiin läpi sitä, miten koneoppimisen menetelmät ovat usein suuri osa siitä, mitä ihmiset yleensä tarkoittavat puhuessaan tekoälystä. Eräs haastateltavista kuvaa tekoälyn ja koneoppimisen suhdetta näin:

Koneoppiminen kuulostaa paljon omaksuttavammalta, että esimerkiksi on käyttäjiä ja tietokone säilöo käyttäjän klikkauksia tai hakutapoja... Tekoäly kuulostaa mun korviin siltä, että kone on jo ihminen, mikä se ei varmaan ikinä tuu olemaan. Ajattelin, että koneoppiminen on yks osa sitä tekoälyä, että se kone oppii, mutta sitten se tekoäly on vielä potenssiin kymmenen kuin se koneoppiminen.

Yleisesti ottaen tekoäly koettiin laajemmaksi käsitteeksi ja koneoppiminen sen osa-alueeksi. Koneoppiminen koettiin helpommin hahmotettavaksi kuin tekoäly. Vastauksissa koneoppimista kuvattiin aiemmasta käytöstä oppivana koneena, kun taas tekoälyn kuvattiin pitävän sisällään kaikkea mahdollista, jossa kone muistuttaa lähes ihmistä.

8.3 Tekoälyn ja koneoppimisen hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä

Haastavimpana haastatteluteemana oli pohtia tekoälyn ja koneoppimisen soveltuvuutta henkilöstö- ja palkanlaskentajärjestelmään. Tavoitteena oli löytää ongelmakohtia, joita voitaisiin ratkaista tekoälyn tai koneoppimisen menetelmin. Ongelmakohtia ei rajattu suoraan henkilöstö- ja palkanlaskentajärjestelmään, vaan laajemmin myös järjestelmän ylläpitoon tai palkanlaskentatyöhön liittyviin prosesseihin. Teeman käsittelyä alustettiin kertomalla, että haastateltavan ei tarvitse erityisen kriittisesti miettiä, mikä on mahdollista tai järkevää. Tarkoituksena oli pyrkiä vapaaseen ideointiin, jotta voitaisiin saada mahdollisimman paljon erilaisia vaihtoehtoja tekoälyn hyödyntämiseen. Innovaatio voisi olla parannus nykyiseen järjestelmään, tehostusta prosesseihin tai kokonaan uusi toiminnallisuus. Ongelmakohtien havaitseminen tai uusien asioiden ideointi ei ole helppoa, varsinkaan miettimällä asiaa juuri jossain tiettyssä tilanteessa.

Tästä huolimatta haastateltavat löysivät useita ongelmakohtia ja ratkaisuehdotuksia.

Palkanlaskennan olennainen vaatimus on virheettömyys. Useimmat haastateltavat olivat mieltäneet palkanlaskennan tietojen virheettömyyden tarkistamisen ongelmakohdaksi, joka on vielä enimmäkseen käsin tehtävää työtä. Suuri osa virheistä vältetään jo tietojen tallennushetkellä, jos ilmoitettavat tiedot vaan ovat oikein. Tietojen ilmoittamiseen on liitetty myös automaattisia tarkistuksia, jotka löytävät osan virheistä. Kuitenkin vielä palkanajojen yhteydessä ohjelma löytää virheellisiä tai puutteellisia tietoja, jotka palkanlaskijan täytyy korjata ennen kuin kaikkien palkansaajien palkanlaskenta saadaan valmiiksi. Virhekorjausten automatisointi nousi esiin yhdeksi palkanlaskentatyötä helpottavaksi ja nopeuttavaksi kehityskohteeksi. Haastateltavat pohtivat, olisiko tekoälyn mahdollista oppia virhetyyppejä ja niihin liittyviä korjauksia, jolloin se voisi ehdottaa käyttäjälle tiettyjen korjausten tekemistä automaattisesti. Eräs haastateltavista pohti mahdollisia tekoälyn hyödyntämiskohteita seuraavasti:

Ainakin erinäisten virhekäsittelyiden tekemiseen, varmaan voitais opettaa tiettyjä tapauksia sille (tekoäly), että miten niitä hanskattais ja tehtäis korjaavia toimenpiteitä.

Palkanajo etenee useassa eri ohjelmavaiheessa kohti palkkojen maksua. Järjestelmäkehityksessä on jo aiemmin suunniteltu lisättävän automaatiota palkanajon tehostamiseksi. Nykyisin palkanlaskija käynnistää tai ajastaa käynnistymään palkanajon yhden vaiheen kerrallaan, mutta tulevaisuudessa palkanajo-ohjelmat käynnistyisivät automaattisesti ennalta laaditun suunnitelman mukaisesti. Haastateltavat pohtivat tekoälyn soveltamisen mahdollisuuksia ajoketjujen eri vaiheissa esiin tulevien virhetilanteiden käsittelyssä. Ajoissa voi löytyä virheellisiä tietoja, joista osa voi olla ajoketjun keskeyttäviä, jolloin seuraavaa vaihetta ei voi aloittaa ennen kuin edellisen vaiheen virhetilanne on käsitelty. Tähän tilanteeseen yksi haastateltavista pohti, että ohjelma voisi oppia virheiden vakavuusasteesta, ja lievemmissä tapauksissa ajo voisi jatkaa virheestä huolimatta seuraavaan vaiheeseen:

Kun tulee palkanajoketjuja, sinne väliin sitten, että katotaan miten edellinen vaihe on mennyt. Sit jatketaan, jos ei oo mitään vakavaa, pitää opettaa mitkä virheet ovat sellaisia, että pitää jättää kesken ja minkä jälkeen voi jatkaa. Ja kuka haluaa, että mistäkin vaiheesta laitetaan poikki, että se ei varmaan sovi kaikille edes sama käytäntö.

Kun kaikki palkanlaskentajärjestelmän löytämät virheet on korjattu ja palkanlaskenta on valmistunut, palkanlaskijan on vielä varmistuttava palkanlaskenta-aineiston oikeellisuudesta. Varmistuakseen oikeellisuudesta, palkanlaskija ajaa erilaisia raportteja ja vertaa niitä aikaisempiin kuukausiin. Virheiden havaitseminen voi olla vaikeaa ja osittain sattumanvaraistakin. Kun tietoja tallennetaan, ohjelma tarkistaa, että tiedot ovat oikeassa muodossa, esimerkiksi odotetaanko numeerista tai tekstimuotoista tietoa. Jos numeeriseen tietoon syötetään arvo, joka on oikeassa muodossa, ei tiedon oikeellisuutta tarkisteta järjestelmässä, vaikka se poikkeaisi huomattavasti aiemmista arvoista. Eräs vastaajista pohtii

palkanlaskennan tietojen oikeellisuuden tarkistamista ongelmakohtaksi, johon voitaisiin hyödyntää tekoälyä:

Palkanlaskennassa on kauhean tärkeää, että jokaisella on oikein palkka ja ne kaikki tiedot, että onko nämä kaikki 50000 palkkaa mennyt oikein... siihen tarkastukseen ja tietojen täsmäytykseen, siihen varmaan vois jotain semmosia (tekoälyn hyödyntäminen), kerta ne (palkanlaskijat) tekee sitä tosi paljon käsityönä. Niinku ajelee erilaisia raportteja ja tsekkaa niitä keskenään... ei pelkästään se palkanlaskenta, vaan tulorekisterit ja muut sidosryhmät, että niiden tiedot ovat oikein myös.

Tietojen tallennusten yhteydessä palkanlaskijat kiinnittävät eniten huomiota yksittäisten palkansaajien tietoihin, mutta palkanajojen yhteydessä tehdään myös tarkistuksia isommille palkanlaskentayksiköille. Koska palkansaajia voi olla tuhansia tai jopa kymmeniä tuhansia, ihmisen on mahdotonta hahmottaa näin suurta datamäärää. Palkanlaskija voi verrata kokonaissummien määriä tai tarkastaa yksittäisiä henkilöitä pistokokeenluoteisesti.

Useat haastateltavat toivat esiin, miten paljon järjestelmässä on työsuhteisiin liittyvää tietoa vuosien ja jopa vuosikymmenien ajalta. Haastateltavat pohjivat tietojen hyödyntämistä uusilla tavoilla. Yhtenä ajatuksena oli yhdistellä ja tutkia riippuvaisuuksia työsuhteisiin liittyvistä tiedoista tiedonlouhinnan avulla, kuten yhdistämällä nimikkeitä, työsuhteiden pituuksia, yksiköitä, poissaoloja, varhaista eläköitymistä tai sairauseläkkeitä. Eräs haastateltavista pohdiskeli asiaa näin:

Poissaolot aina kiinnostaa varmaankin työnantajaa ja siihen liittyvät kulut. Luulen, että niitä seurataan jo. Sitten on datamäärästä saatavaa tietoa, liittyen vaikka onko se paikkakuntasidonnaista, työpistesidonnaista, tällaisia korrelaatioita voisi löytää... vaihtuvuus tai nimikkeiden suhde poissaoloihin.

Haastateltavat pohtivat myös olemassa olevien tietojen hyödyntämistä esimerkiksi budjetointia varten. Raporteilla voidaan saada tietoa menneestä ajasta, mutta voisi olla hyödyllistä, jos voisi saada analyysin tai ennusteen tulevasta. Haastateltavat mainitsivat hyödyllisiksi tiedoiksi esimerkiksi henkilöstö- ja palkkakulujen suunnan tulevaisuudessa pohjautuen aiempaan dataan:

Ennustettavuutta palkkakulujen tai poissaolojen tai tällaisten suhteen, että saatais ajettua raportti ns. tulevaisuudesta, joka antais ees sinnepäin jonkun tilaston, kun viime vuonna tähän aikaan oli tän verran, et jos sieltä näkyy jotain trendejä.

Haastateltavat mainitsivat, että voisi olla hyödyllistä pystyä arvioimaan, miten muutokset toimintaympäristössä vaikuttavat henkilöstötyövuosiin ja kuluihin. Palkankorotusten yhteydessä voisi olla hyödyllistä simuloida palkankorotusten jakamisen järkevällä tavalla. Kiinnostavia voisivat olla myös palkkaustason tassa-arvoisuus ja kilpailukykyisyys verrattuna vastaaviin toimialoihin. Yksi haastateltavista pohti myös yksittäisten työntekijöiden palkanmääräytymistä ja miten nykytilanteessa palkanmääräytyminen voi olla helposti epäoikeudenmukaistakin:

Miten se ihmisen palkka ylipäätänsä määräytyy, niin siihenhän tekoäly olisi hirveen hyvinkin. Tietysti siihen tulee tää etiikka ja miten se lasketaan, että kuka sen ohjelmoi, mutta jos pystyttäisi laittamaan ihmisen työtehtäville joku arvo ja sitten sille laadulle arvo ja muuta, että ainakin se pystyis ehdottamaan, että tämä ihminen toimii hyvin tässä... Nyt on tavallaan ei-kenenkään tiedossa, jos et sä pidä omia puolia, niin kukaan ei oikeastaan tiedäkään, että teetkö sä asioita hyvin vai huonosti.

Resurssien optimoinnin mahdollisuus tuli esiin muutamassa haastattelussa. Esimerkiksi sairaalaympäristössä tarvitaan eri asiantuntijoita ja on varmistuttava, että henkilökuntaa on riittävästi saatavilla. Sairaaloissa tarvitaan runsaasti sijaisia lyhyisiin, jopa vain päivän pituisiin työsuhteisiin. Olisiko mahdollista arvioida henkilöstö- ja palkanlaskentajärjestelmän poissaoloihin ja lomiin liittyvän aiemman datan perusteella sijaisten tarvetta pitkänäköisemmin ja ketjuttaa lyhyitä sijaisuuksia pidemmiksi sijaisuuksiksi odotettavissa olevan tarpeen mukaan? Yksi haastateltavista kuvasi ajatuksiaan seuraavasti:

On aika paljon pätkäsijaisuuksia, päivän sijaisuuksia, että jos ne (data-analytiikka) pystyis ennustamaan poissaoloja vähän fiksummin... ihmiset on töissä yhen päivän sopparilla ja sitten seuraava päivä joskus viikon päästä, jos ne pystyis niitä niputtamaan tai jotain, että helpottais sitä työnantajan hommaa.

Arkielämästä tutut ominaisuudet eri palvelujen mukautumisesta aiemman käytön mukaisesti ja ohjelmien tekemät suositukset herättivät pohtimaan myös henkilöstö- ja palkanlaskentajärjestelmää tästä näkökulmasta. Järjestelmän käyttöliittymä voisi mukautua aiemman käytön mukaan. Useammin käytetyt elementit olisivat näkyvämmiin saatavilla. Käyttöliittymä voisi myös suositella toimintoja, joita käyttäjä on aiemmin käyttänyt. Muuan haastateltava pohti käyttöliittymän mukautuvuutta seuraavasti:

Se visuaalinen puoli mikä näkyy koko ajan käyttäjälle, niin siihen puoleen pystyis varmaan jollain tavalla soveltamaan tekoälyä. Tallennetaan käyttäjän liikkeitä ja voidaan ottaa sieltä semmosia pieniä palasia tai toisiinsa liittyviä kokonaisuuksia ja niiden perusteella esimerkiksi luoda käyttöliittymään elementtejä, että nää on kiinnostanut sua aiemmin, että kiinnostaisko nää sua nyt?

Henkilöstö- ja palkanlaskentajärjestelmän ylläpidon olennainen osa-alue on asiakaspalvelu ja asiakkaiden ongelmatilanteiden ratkaisu. Osa haastateltavista pohti chatbotin soveltuvuutta henkilöstö- ja palkanlaskentajärjestelmän asiakastuen tarpeisiin. Yksi haastateltavista kuvasi asiakastuen tilannetta seuraavasti:

Aika paljonhan noilla incidenteilla (palvelupyynnöillä) pyörii samoja kysymyksiä, joihin pystyy antaa hyvinkin suoraan vastauksia vanhan datan pohjalta, jota on siellä, koska kaikki vanhat incidentit on tallessa siellä järjestelmässä, mitä on vuosien saatossa tullut... eli ei tarte joka kerta keksiä pyörää uudestaan.

Järjestelmän ylläpidossa palvelinpuolen ratkaisut ja tietoturva ovat keskeisessä asemassa. Yksi haastateltavista pohti tekoälyn hyödyntämistä skaalautuvissa palvelimissa. Olemassa olevasta datasta olisi todennäköisesti mahdollista arvi-

oida käyttäjämäärien vaihtelua ja laskentatehon tarvetta tulevaisuudessa. Ennakolta voitaisiin arvioida, että tiettyihin aikoihin tehdään paljon lomajärjestelyjä, jolloin käyttäjiä on enemmän ja myös laskentatehon tarve kasvaa tavallista suuremmaksi. Hiljaisempina aikoina ei ole tarvetta varata yhtä paljon laskentatehoa. Tällä hetkellä järjestelmän ylläpidossa ei oteta huomioon vaihteluita, vaan on varauduttu oletetusti suurimpaan mahdolliseen tarpeeseen ja hiljaisimpina aikoina käytetään vain murto-osaa varatusta kapasiteetista. Haastateltava kuvaa tilannetta:

Jos meillä olisi esimerkiksi skaalautuvat järjestelmät, siis alustan puolesta, niin silloin vois oppia datasta, kuinka paljon käyttäjiä on milloinkin... Todennäköisesti tiettyyn aikaan siellä on paljon käyttäjiä, jolloin voitais skaalata valmiiksi, ettei se kyykkää, jolloin voitais ajaa niitä hiljaisempia aikoja pienemmällä laskentateholla, joka olis sit taas halvempaa sen aikaa.

Eräs haastateltavista mainitsi myös palvelunpuolen laiterikkojen ennustamisen yhtenä sovelluskohteena aiemman datan hyödyntämiseen. Lisäksi tietoturvan näkökulmasta tekoälyn sovellusten avulla voidaan seurata, onko järjestelmän käyttö normaalia, ja havaita tietoturvahyökkäykset tai yritykset päästä järjestelmään ilman oikeuksia.

Tulevaisuuden trendinä nähtiin terveysteknologian yhdistäminen palkkaukseen. Älykellot ovat yleistyneet, jolloin tietoa unesta, liikunnasta ja palautumisesta voitaisiin käyttää esimerkiksi lisäpalkkauksen perusteena terveydestä huolehtimisen vastineena. Eräs haastateltavista näkee tulevaisuuden trendin seuraavasti:

Ihmisillä kun alkaa olla näitä terveyskelloja... kyllä se varmaan on silleen, että sitä hyvinvointia kaikilla mittareilla mitataan. En mä pitäis ite ollenkaan pahana, että se kannustais siihen, että ihmiset vois hyvin, ja olis vapaa-aika ja työ balanssissa. Silloin se työura olis pidempi ja ei niin paljon sairauspoissaoloja ja kaikkea... kymmenen tai kahenkymmenen vuoden päästä en yhtään ihmettelis, jos se olis palkkaukseen vaikuttava tekijä.

Haastateltavat pohtivat asiaa myös päinvastaisesti tuoden esiin asioita, joihin tekoälyä ei kannattaisi soveltaa tai mihin sen käytöllä voisi olla suuremmat riskitekijät. Palkanlaskentaan suoraan vaikuttavia tekijöitä pidettiin liian riskialttiina tekoälyn hyödyntämiselle. Palkanlaskennan täytyy mennä sentilleen oikein ja siihen vaikuttavien tekijöiden tulee olla nähtävissä vielä useiden vuosien päästäkin. Tekoälyn läpinäkymättömyyttä pidettiin riskinä ja sen koettiin vaikeuttavan varmistumista sovelluksen oikeasta toiminnasta:

Mitä kannattaa tehdä ja mitä ei kannata tehdä. Et kannattaako sinne ajaa neuroverkko sisään heti, ja sit kukaan ei tiä, et laitetaan dataa sisään ja sieltä tulee jotain pihalle, et kukaan ei tiä mitä se tekee siinä välissä.

Mä ajattelen sinänsä, että tekoälylle ja koneoppimiselle siinä pitäisi olla jonkun veran semmoista liikkumavaraa ja siellä pitäisi olla semmosta virheiden ja riskienhallintaa paljon enemmän, koska se tekoäly tai koneoppiminen voi erehtyä tosi paljon,

millä tavalla henkilölle lasketaan palkkaa. (Palkanlaskennassa) voi mennä paljon enemmän pieleen kuin jossain käyttöliittymässä.

Tekoälyn itsenäistä päätöksentekoa ei myöskään koettu turvalliseksi. Tekoälyn roolina nähtiin olla ihmisen työtoveri, joka vahvistaisi ihmisen päätöksentekoa, mutta ei kokonaan korvaisi ihmistä. Tekoälysovellus voisi tehdä ehdotuksia ja tarjota ratkaisuvaihtoehtoja. Tekoälysovellusten yleistyessä ihmiselle jäisivät haastavammat asiantuntijan tehtävät, ja koneelle voitaisiin siirtää rutiininomaisia tehtäviä.

8.4 Käytettävissä oleva data ja tulevaisuuden datatarpeet

Dataa käsittelevässä haastatteluteemassa tarkasteltiin olemassa olevia datalähteitä ja arvioitiin tulevaisuuden tarpeita datan keräämisessä. Kaikki vastaajista mainitsivat arvokkaana datana henkilöstö- ja palkanlaskentajärjestelmän tallentamat tiedot. Arvokkaana pidettiin, että henkilöstö- ja palkanlaskentajärjestelmässä tallennettu data on määrämuotoista ja sitä on pitkältä aikaväliltä eri tyyppisiltä asiakkailta. Dataa tallennetaan järjestelmän käytön tarpeiden mukaan, kuten vastaamaan kirjanpidon ja lainsäädännön edellyttämiin vaatimuksiin.

Useat haastateltavat mainitsivat vastauksissa muina arvokkaina datalähteinä järjestelmän ylläpidossa kertyvät lokitiedot ja asiakaspalvelujärjestelmän tallentamat palvelupyynnöt. Lokitietoihin tallentuu tietoja mm. järjestelmään kirjautumisista, tallennetuista tapahtumista ja virhetilanteista. Asiakaspalvelun palvelupyynnöjä on tallentunut vuosien kuluessa runsaasti, mutta niiden hyödyntämistä pidettiin mahdollisesti vaikeana, koska data on pääasiassa jäsenymätöntä tekstimuotoista dataa. Palvelupyynnöjä ei mahdollisesti ole luokiteltu riittävällä tarkkuudella, jolloin ei ole tiedossa, mihin järjestelmän osaan tai toimintoon ongelmat ovat liittyneet. Asiakkaat nimeävät palvelupyynnöt, mutta lopullinen ratkaisu onkin voinut olla jokin muu, kuin alun perin on ajateltu.

Koneoppimisen myötä tarve tiedon tallentamiseen voi muuttua. Haastateltavat olivat melko maltillisia tietojen tallennuksen lisäämisessä. Vastaajien mielestä ei ole järkevää alkaa tallentamaan kaikkea mahdollista, vaan pitäisi ensin olla edes alustava ajatus mahdollisesta tulevaisuuden käyttötarpeesta. Haastateltavat kuvasivat, että lokien käyttöä voitaisiin lisätä, koska on hyvin mahdollista, että pitäisi tietää tarkemmin mitä käyttäjät missäkin vaiheessa tekevät, jotta voitaisiin saada opetusdataa koneoppimista varten. Yksi haastateltavista kuvaa nykyisen datan käyttömahdollisuuksia seuraavasti:

Vois käyttää analyttiseen tietojenkäsittelyyn tai johonkin tämmöiseen, että ennakoitais jotain asiaa, johonkin sellaiseen se vois sopia sellaisenaan, mutta en mä tiedä miten sen perusteella opettais tekemään jotain asioita. Et siellä ei ehkä ole sellasta ketjua, että mitä missäkin tapahtuu.

Yksittäiset haastateltavat ehdottivat datan keräämisen lisäämistä palvelinpuolen lokeihin ja muutoshistorian tarkempaa tallennusta henkilöstötietojen tapah- tumista. Virhelokien lisääminen ja eriyttäminen muista lokitiedoista sekä säily- tysaikojen pidentäminen mainittiin keinoina lisätä arvokasta dataa tulevaisuu- den tarpeisiin. Jos olisi tarvetta saada tarkempaa tietoa käyttöliittymän käytös- tä, olisi mahdollista tallentaa käyttäjän tekemiä valintoja joistakin kohdista. Kaikkien käyttäjän tekemien valintojen tallentaminen nähtiin mahdottomana. Jos kaikkea tarvittavaa dataa ei ole koneoppimista varten valmiina, joitakin voidaan myös itse tuottaa, kuten dataa erilaisista virhetilanteista.

8.5 Tekoälyprojektin aloittamisen edellytykset

Haastateltavat miettivät erilaisia näkökulmia tekoälyn hyödyntämisen aloitta- miseen. Monet vastaajista pohtivat asiaa tavoitteiden kautta ja näkivät erilaisia organisointimahdollisuuksia tekoälyn soveltamisen tavoitteiden näkökulmasta tarkasteltuna. Tavoitteita tarkasteltiin aikataulun, toteutuksen laajuuden ja vaa- tivuuden näkökulmista. Jos työaika on runsaasti käytettävissä, olisi mahdollis- ta tehdä kokeiluja omilla henkilöstöresursseilla. Henkilöstön koulutuksiin olisi mahdollista varata riittävästi aikaa ja yrityksen ja erehdyksen kautta olisi mah- dollista alkaa opettelemaan uutta teknologiaa. Kun taas, jos taas aikataulu on tiukka, nähtiin tärkeämpänä hankkia asiantuntemusta tiimien ja mahdollisesti myös oman organisaation ulkopuolelta. Jos toteutuksesta odotetaan vaativaa, kuten uutta ominaisuutta tai tuotetta henkilöstö- ja palkanlaskentajärjestelmän yhteyteen, koettiin asiaan liittyvän enemmän riskejä. Haastateltavat toivoivat riskien vähentämiseksi, että toteutus aloitettaisiin valmistamalla ensin proto- tyyppejä, jolla voidaan kokeilla idean toimivuutta.

Haastateltavat pitivät tärkeänä nostaa koko henkilöstön tietämystasoa te- koälystä. Tekoälyn ja koneoppimisen perustiedoista toivottiin koko henkilöstöl- le tarkoitettua koulutusta. Yleisen koulutuksen toivottiin luovan jonkinlaisen pohjan yhteiselle keskustelulle ja ylipäättänsä lisäävän keskustelua aiheesta. Kaikille avointa Helsingin yliopiston *Elements of AI* -verkkokoulutusta pidettiin yhtenä hyvänä vaihtoehtona kaikille soveltuvana koulutuksena. Muuan haasta- teltavista kuvaa koulutustason nostamista seuraavasti:

Ehkä vois olla joku yleismaailmallinen koulutus, josta saa peruskäsityksen erilaisista keinoälyn osa-alueista ja mistä se on lähtenyt ja mitä sillä oikein tarkoitetaan ja min- kälaisia sovellutuksia on ja muuta. Saa kuvan mikä juttu tää on ja omat rajoitteensa on ja omat aikamoiset haasteensa on joka tapauksessa. Tietäisivät ihmiset enemmän sitten siitä.

Tekoälystä kiinnostuneille kehittäjille nähtiin koulutustarve datan käsittelyn ja koneoppimisen teknologioihin, joista haastatteluissa mainittiin nimeltä data- massojen käsittelyyn tarkoitettu Apache Hadoop, R-ohjelmointi ja Pythonin tekoälykirjastot. Teknologisten valintojen tekeminen auttaisi suuntaamaan kou-

lutukset juuri oikeisiin teknologioihin, mutta luonnollisesti kaikki koulutus lisää osaamista, vaikka lopulta käytettäisiin eri teknologiaa kuin koulutuksessa. Mitä paremmin henkilöt hahmottavat tekoälyn teknologioiden menetelmät ja mahdollisuudet, sitä paremmin on mahdollista havaita tekoälysovelluskohteita. Vastaavasti on hyvä tuntee myös tekoälyn teknologioiden soveltamisen rajoitteet ja haasteet.

Haastateltavat pitivät tärkeänä, että kaikille selkiytyisi, mikä on se ongelma, jota tekoälyn menetelmin ollaan ratkaisemassa ja saataisiin varmuus, että valitut menetelmät olisivat ongelmanratkaisun kannalta oikeat. Haastateltavat ehdottivat aivoriihimäistä työskentelyä omalla porukalla tai tekoälyn hyödyntämistä tuntevan asiantuntijan johdolla. Asiantuntija voisi auttaa varmistumaan suunnitellun ongelmanratkaisun pätevyydestä ja ohjata alusta asti oikeaan suuntaan toteutuksessa. Osa haastateltavista näki mahdolliseksi, että ensimmäinen toteutus voisi pohjautua jo nyt olemassa olevaan dataan, koska se nopeuttaisi aloitusta. Samalla voisi jo miettiä jatkoa ja muita datatarpeita, jolloin tallennettavia tietoja voisi tarpeen mukaan kerätä lisää tulevaisuutta varten. Oman tekemisen ja ulkopuolelta ostetun toteutuksen määrä vaihteli eri haastateltavien välillä. Osa haastateltavista pohtivat, että määrittely voitaisiin tehdä itse, mutta ainakin ensimmäisessä vaiheessa toteutus ostettaisiin kokonaisuudessaan ulkopuolelta. Toteutuksen jälkeen tekoälysovelluksen ylläpidon ja jatkokehityksen kautta pyrittäisiin lisäämään omaa osaamista. Eräs haastateltavista kiteytti osaamiseen liittyviä haasteita seuraavasti:

Neuroverkko on jo aika pitkällä, matemaattisilla malleilla nyt ensin ainakin, mut nekin vaatii jo et pitäis vähän ymmärtää niitä mallejakin eikä vaan koodausta... en tiää olisko halvin, mutta helpoin ja turvallisin ratkaisu olis ostaa sitä (toteutusta) palveluna ainakin alkuun jostain... tehään ite ylläpito ja jatkokehitys.

Haastateltavat pitivät osaamisen jäämistä omaan yksikköön niin tärkeänä, että ulkopuolista apua voitaisiin käyttää sopivassa suhteessa, mutta kuitenkin hyödyntäen omaa työpanosta mahdollisimman paljon. Vähintäänkin konsultointiavun saatavuutta pidettiin tärkeänä omien kokeilujen tueksi, jolloin voisi saada apua ongelmatilanteissa, joista ei ole entuudestaan kokemusta. Rekrytointia pidettiin yhtenä vaihtoehtona lisätä oman organisaation osaamista. Muuan haastateltavista kuvaa näkemystään seuraavasti:

Siinä olis hyvä olla joku, jolla on enemmän kokemusta, että ei menis niin paljon aikaa siihen, että me ylipäätään selvitetään, että mitäs tää ylipäätänsä tarkoittaa. Ihan ajankäytön kannalta. Vois olla sellainen, joka osais ohjata sitä ryhmää. Ehkä pitää miettiä onko syytä rekrytoida, kuinka pitkä se projekti on ja onko meillä kertynyt tietämystä ja osaamista... mutta ei missään tapauksessa kokonaan (ulkoisteta) muualle.

Projekti koettiin hyväksi tavaksi organisoida kokonaan uuden asian opettelua ja kehittämistä, koska silloin tulisi selkeästi määriteltyä tavoitteet ja aikataulut. Projektilla olisi myös johtaja, joka seuraa aikataulua ja edistymistä. Projektin tavoitteiden mukaisesti täytyisi ratkaista haasteet, jotka liittyvät määrittelyyn,

osaamistason nostamiseen ja datan käyttöön sekä tehdä teknologiset valinnat toteutusta varten. Eräs haastateltavista kuvasi näkemystään organisoitumisesta:

Kyllä siinä pitää olla joku projekti, joka koordinoi sen ja pitää langat käsissään. Pitää olla oma ryhmä, joka pitää huolen, että etenee aikataulussa ja budjetissa myös... ja joka tietää missä se kokonaisuus on menossa ja kuinka lähellä valmista.

Projektimuotoista työskentelytapaa pidettiin tehokkaana tapana organisoida tekoälysovelluksen tekemistä. Haastateltavat korostivat riittävien resurssien merkitystä toteutuksen etenemiselle. Yksikään haastateltavista ei nähnyt realistisena toteutuksen tekemistä oman normaalin työn ohessa. Haastateltavat toivoivat, että työhön valittaisiin oma tiimi, joka voisi keskittyä tekoälyprojektiin. Projektissa tarvitaan erilaista kokemusta ja monen eri osa-alueen asiantuntemusta. Haastateltavien mielestä olisi tärkeää, että tiimissä olisi alusta asti mukana kaikki henkilöt, jotka projektin työtä tulevat tekemään, huomioiden eri työvaiheet, kuten suunnittelun, määrittelyn, kehityksen, testauksen ja ylläpidon.

8.6 Tekoälyn omaksumisista edistävät tekijät

Hyödyllisenä asiana koettiin organisaation pitkä kokemus henkilöstö- ja palkanlaskentajärjestelmän kehityksestä. Ydinosaamisen tunteminen auttaa havaitsemaan kohteita, joissa tekoälyä voitaisiin hyödyntää. Läheiset suhteet asiakkaiden kanssa mainittiin myös vahvuutena, joka voisi mahdollistaa tekoälysovelluksen kehittämisessä yhdessä asiakkaiden kanssa. Pilottiasiakkaat ovat aiemminkin olleet avainasemassa kehitystyön suunnittelussa ja laadunvarmistamisessa, joten aiemmin käytettyjä menetelmiä voitaisiin hyödyntää myös tekoälysovelluksen kehittämisessä. Asiakkaiden kanssa tehty yhteistyö voisi lisätä asiakkaiden luottamusta ja kiinnostusta tekoälysovelluksen kehittämiseen. Eräs haastateltavista pohti yhteistyön merkitystä seuraavasti:

Meillä on ainakin kyky selvittää, esimerkiksi asiakkailta asiakaslähtöisesti mitä siellä kaivataan, mitä sieltä uupuu tällä hetkellä ja mikä olis todella hyödyllistä asiakkaille.

Henkilöstön asenne ja oppimisinnostus mainittiin vahvuuksina, joista olisi hyötyä tekoälyn hyödyntämisen aloittamisessa. Haastateltavilla on ohjelmointi-, tietokanta- ja palvelinosaamista, ylipäättänsä kaikki järjestelmäkehitysosaaminen nähtiin vahvuutena uusien taitojen oppimista ajatellen, koska jo olemassa olevien taitojen lisäksi on helpompi hankkia uutta osaamista. Osa haastateltavista on jo hankkinut lisää tietoa ja opiskellut joitakin tekoälyyn liittyviä verkkokursseja. Jonkin verran haastateltavat arvelivat, että uusia menetelmiä kohtaan voisi olla muutosvastarintaa yleisellä tasolla, mutta kehitystiimien sisällä oltiin kiinnostuneita mahdollisuudesta uuden oppimiseen:

Me ollaan aika semmosia työntösiä, että ei me olla ikinä pelätty, että me otetaan uusia asioita vastaan, ollaan ihan innokkaasti lähetty uusiinkin hankkeisiin mukaan.

Henkilöstö- ja palkanlaskennan järjestelmäkehityksen kehittäjillä on vahva tietämys järjestelmästä, jolloin he ymmärtävät järjestelmän sisältöä ja tavoitteita. Järjestelmän sisällön tuntemusta ei voi saavuttaa hetkessä, vaan se voi viedä kuukausia tai jopa vuosia. Jos rekrytoidaan henkilö, jolla on aiempaa kokemusta tekoälyn teknologioista, henkilöstö- ja palkanlaskennan tuntemus todennäköisesti puuttuu. Molempien osa-alueiden hallinta on tärkeää hyödyllisen tekoälysovelluksen kehittämisessä.

Tiimi on osa isoa organisaatiota, ja sen koettiin tuovan etua tekoälysovellusten kehittämiseen. Osaamista voisi olla helpommin saatavissa toisesta organisaatiosta konsernin sisältä. Konsernin tuotteissa on myös samankaltaisuuksia, jolloin voidaan mahdollisesti ottaa mallia muista tuotekehitysprojekteista. Organisaation koko vaikuttaa myös resursseihin, joilla voidaan hankkia tarvittavaa osaamista koulutusten, rekrytoinnin tai alihankinnan kautta.

Vahvuutena nähtiin myös jo valmiina oleva henkilöstö- ja palkanlaskennan data, jolloin voidaan pyrkiä kehittämään sovellusta, jossa lähdetään liikkeelle olemassa olevasta datasta. Monipuolisesta data-aineistosta on mahdollisuus kehittää monenlaisia sovelluksia. Tämä nopeuttaa aloitusta, koska datan kerääminen voisi viedä aikaa.

8.7 Tekoälyn omaksumisista hidastavat tekijät

Tekoälyn hyödyntämisen vaikeus tuli esiin kaikista vastauksista. Tekoälyn hyödyntäminen on perinteiseen ohjelmointityöhön verrattuna hyvin erilaista ja sen takia on vaikea hahmottaa soveltuvia kohteita tekoälyn hyödyntämiselle. Monet vastaajat kokivat, että yksittäisten työvaiheiden oppiminen on hyvinkin toteutettavissa, mutta kokonaisuutena asian hallitseminen on erittäin vaativaa. Yksi vastaajista tiivistä hyvin asian haastavuuden kokonaisuutena:

Yks isoin tekijä hidastamaan tätä koko prosessia (tekoälyn hyödyntäminen) on se tekoälyn ja koneoppimisen hankaluus, että mitä me oikeasti halutaan sillä ja miten me saavutetaan se ja miten me sitten katotaan testauksen avulla, että se oikeasti toimii.

Henkilöstö- ja palkanlaskentajärjestelmän haasteena on valtava määrä variaatioita. Asiakaskohtaiset eroavaisuudet ovat merkittävät. Järjestelmä mahdollistaa asiakaskohtaisten säätöjen tekemisen, jolloin samaa järjestelmää voidaan käyttää hyvin eri tavoin erilaisiin tarkoituksiin. Haastateltavat pohtivat voitaisiinko samaa tekoälyn sovellusta käyttää kaikille asiakkaille vai vaatisiko se silti runsaasti resursseja muokata sovellusta eri asiakkaille sopiviksi. Haasteena ei ole pelkästään erottaa asiakaskohtaisia eroavaisuuksia, vaan myös yhdellä asiakkaalla voi olla useita työehtosopimuksia, jolloin myös henkilötasolla voikin olla eri tavalla käsiteltäviä poikkeuksia. Yksi haastateltava kuvaa tekoälyn hyödyntämisen haasteita seuraavasti:

Aina sen palkanlaskijan pitää kuitenkin tarkastaa se lopputulos, koska on niin paljon tessejä (työehtosopimuksia), joita järjestelmässä pitää tukea, että jokaisessa henkilössä on omat nyanssinsa, mikä vaikuttaa siihen, että ei menekään niin kuin massan pitäisi.

Hidastavana tekijänä voidaan nähdä myös, että tiedonlouhintaan ja tekoälyn soveltamiseen liittyviä teknologioita ei ole aiemmin käytetty haastatelluissa tiimeissä. Vaikka perinteisestä järjestelmäkehityksestä on vuosien kokemus, data-analyysin hyödyntämisen kokemus puuttuu. Tietoja tallennetaan järjestelmän tarpeisiin, mutta erityisemmin ei ole mietitty, miten jo olemassa olevaa tietoa voitaisiin hyödyntää uudella tavalla. Haastateltavat pitivät haasteena myös olemassa olevien teknologioiden yhteensopivuutta uusien teknologioiden kanssa. Käytössä olevat palvelinalustat ja muut palkanlaskentaa ohjaavat ja suoritavat teknologiat, eivät välttämättä ole yhteensopivia tekoälyn hyödyntämisen teknologioiden kanssa. Teknologisen epävarmuuden lisäksi myös dataan sopivuudesta koneoppimisen kouluttamiseen on epävarmuutta.

Tekoölyyn liittyvä osaamisen puute nostettiin esiin kaikissa vastauksissa. Osaamista voidaan lisätä täydennyskoulutuksella. Osalla haastateltavista oli kokemusta verkkokursseista, joita on voinut opiskella oman aikataulun mukaan. Haastateltavien vastauksissa nousi esiin, että on ollut vaikea saada tietoa verkkokoulutusten sisällöistä ja löytää itselle sopivan tasoista koulutusta, jota voisi hyödyntää käytännössä. Verkkokurssien yhdeksi ongelmaksi koettiin vuorovaikutuksen puute ohjaajan kanssa. Koulutuksen lisäksi osaamista voidaan hankkia myös oman organisaation ulkopuolelta, mutta hidasteena voi olla rekrytointien vaikeus, koska osaajista on pulaa. Toisissa organisaatioissa oman konsernin sisällä voi olla enemmän osaamista, mutta epäselvää on, olisiko mahdollista saada osaamista muista organisaatioista. Haastateltavat kokivat ongelmaksi yleisen resurssien vähyyden, koska resursseja on käytetty järjestelmän yleiseen kehittämiseen ja uudistamiseen. Haastateltavat eivät nähneet mahdollisuuksia nykyisten työtehtävien ohessa omaksua tekoälyn teknologioita, ellei selkeästi osoiteta lisää resursseja tekoälyn hyödyntämisen kehittämiseen.

8.8 Tekoälyn hyödyntämisen mahdollisuudet ja riskit

Tekoälyn hyödyntämiseen koettiin liittyvän riskejä. Kuten edellisessä kappaleessa todettiin, tekoälyn teknologioiden osaamisen puute oman organisaation keskuudessa koettiin yhdeksi suurimmista hidasteista. Osaajien rekrytointi voisi osoittautua myös haasteelliseksi. Toisaalta myös kehityksen ulkopuolelle jäämistä pidettiin riskinä. Jos kilpailija pystyy hyödyntämään tekoälyä tavalla, jolla on merkittävä vaikutus asiakkaisiin, se voisi tuoda kilpailijalle useamman vuoden kilpailuedun. Tekoälyn hyödyntämiseen voi liittyä riskejä, mutta samalla tavalla riskejä voi liittyä myös tekoälyn huomiotta jättämiseen. Muuan haastateltavista kiteytti tekoälyn dilemman seuraavasti:

Et ei varmaan voi olla tekemättä mitään, et vaikka siinä ois riskejä... käyks siinä sit niin, että kilpailijat teki ja me ei tehty ja asiakkaat ostaa kilpailijalta, kun siltä saa ki- van ennusteen.

Jos vasta myöhemmin lähdetään mukaan kehitykseen, kuilua voi olla vaikea kuroa umpeen, koska kaikki kehitys vaatii pohjatyönsä. Vastaavasti oma onnis- tuminen aikaisessa vaiheessa kilpailijoihin verrattuna, voisi tuoda usean vuo- den kilpailuedun. Huolellisen liiketoimintasuunnitelman tekemistä pidettiin riskienhallinnan kannalta välttämättömänä. Suunnitelmalla voidaan varmistaa, että tehdään jotain, jolla on riittävän suuri merkitys panostuksiin verrattuna. Yksi haastateltavista tiivistä ajatuksia näin:

Jonkinnäköistä hyötyä saadaan aivan varmasti irti, mutta onko se niin hyödyllistä, että kannattaa panostaa x-määrä rahaa siihen. Sitä mä en osaa sanoa. Siinä tietysti voi olla riskinsä.

Liiketoimintasuunnitelman tekemistä vaikeuttaa vaikeus arvioida kehitys- ja ylläpitokustannuksia. Toteutuksessa on myös eri vaihtoehtoja oman kehityksen, ulkoistuksen tai molempien yhdistämisen välillä. Eri toteutustapojen kustan- nusten vertailu on pitkällä aikavälillä vaikeaa. Yksittäisen pienen tekoälysovel- luksen hankinta voisi tulla edullisimmaksi kokonaan ulkopuolisena työnä. Kui- tenkin pitkällä aikavälillä, ulkoistaminen ei tuo osaamista omaan organisaa- tioon. Omassa tekemisessä taas aikaa kuluu runsaammin opetteluun, koska aiempaa kokemusta ei ole. Haastateltavat pohtivat, saadaanko kehitys- ja yllä- pitokulut katettua, jos aikaa kuluu runsaasti teknologian opetteluun. Tarvitaan riittävä sitoutuminen kaikilta osapuolilla, myös rahoitukseen, koska tulosta ei välttämättä tule heti. Eräs haastateltavista kuvaa uuden opetteluun liittyviä aja- tuksia näin:

Aina uusissa projekteissa, jos ei oo tarkkaa käsitystä, mikä on se lopputulos, mitä ta- voitellaan. Se voi olla usko koetuksella, ainakin niiden taholta, jotka rahoittaa sen homman, elikkä siinä pitäis olla todella hyvä tuki ja siihen pitää pystyä luottamaan, että ei tavallaan lähe matto jalkojen alta pois, jos se ei tuukkaan siihen tahtiin, kun ovat toivoneet.

Uusien teknologioiden myötä myös työvaiheita on mietittävä uudestaan. Teko- älyn hyödyntäminen ei ole pelkästään kehityksen näkökulmasta erilainen toi- mintatapa, vaan myös testauksen näkökulma tekoälyn hyödyntämisessä herätti ajatuksia. Tiedon oikeellisuudesta varmistuminen on vaikeampaa datalähtöi- syyden vuoksi kuin perinteisen tietokoneohjelman toiminnan testaaminen. Opetusdatan validointi ja algoritmien ylläpito tuotannon aikana vaativat oman huomionsa järjestelmäkehityksessä. Eräs haastateltavista kuvaa testauksen haasteita:

Miten se testaaja pystyy varmistumaan, että jos jonkinlaisia ennusteita tulee, että se ennuste on oikea? Tai että sen pohjalla olevat tiedot ovat oikein? Koska se massa on kuitenkin niin suuri, ettei sitä voi lähteä millään lailla perkaamaan. Tietysti jossain rajoissa voi pistokokeita tehdä tai muuta, mutta ei silleen ihan hirveesti ja mitä siinä

oikeesti testaat? Sehän se varmaan on tekoälyssä aina, että ei se voi jokaiseen tilanteeseen pätee, se on niinku keskimäärin jotakin.

Henkilöstö- ja palkanlaskentajärjestelmän kriittiset kohdat on varmistettava, ja mietittävä tarkkaan mihin tekoälyn sovellus voidaan turvallisesti lisätä. Esimerkiksi käyttöliittymän ulkoasuun lisääminen olisi melko vaaratonta, mutta palkanlaskennan ytimessä riskit kasvavat selvästi. Tekoälyn soveltaminen voisi aiheuttaa huolta myös käyttäjissä. Eräs haastateltavista kiteytti ihmisten pelkoa teknologiaan näin:

Sit asiakkaat ajattelee, että herrajumala, mun palkat laskee joku robotti, että tässähän voi mennä vaikka kuinka paljon pieleen, että sekin voi olla valttikortti vielä nykypäivänä, että joku ihminen tarkastaa... ihmisillä on epäluottamusta tämmöisissä rahasioissa kaikkeen teknologiaan.

Haastateltavat miettivät myös tekoälyn hyödyntämisen eettisiä näkökohtia. Henkilöstö- ja palkanlaskentajärjestelmä on sovelluskohteena hyvin vaativa, ja eettisten näkökulmien tarkastelu on tehtävä erityisen huolellisesti. Haastateltavat pohtivat datan käytön mahdollisuuksia ja miettivät asiakkaiden halukkuutta tietojen jakamiseen. Yksilöivät tiedot ovat luonnollisesti häivyttävä ennen käyttöä. Eräs haastateltavista arvioi asiakassuhteiden auttavan luvan saamiseen datan käyttöä varten:

Varmaan saa helpommin luvan siihen (datan käyttöön), koska meillä on hyvät asiakassuhteet, silleen tehdään niinku asiakkaitten kanssa ryhmänä kehittämistä, kun on niitä kehitysryhmiä ja muita, jolloin ne itsekin on silleen, että meidän kanssa kannattaa tehdä tätä yhdessä.

Tiedottaminen ja avoimuus ovat avainasemassa tietojen käytössä. Luvat on varmistettava hyvissä ajoin ennen projektin aloitusta, ettei se muodostu esteeksi etenemiselle. GDPR on tehnyt henkilötietojen käsittelystä aiempaa tarkempaa ja myös tietoturvan näkökohtien huomioiminen on tärkeää.

9 TUTKIMUSAINEISTON ANALYYSI JA JOHTOPÄÄTÖKSET

Tässä luvussa esitellään tutkimusaineiston analyysin johtopäätökset TOE-mallin mukaan tarkasteltuna teknologian, organisaation ja ympäristön konteksteissa. Sen jälkeen käsitellään teemahaastatteluissa löydettyjä tekoälyn hyödyntämisen kohteita henkilöstö- ja palkanlaskentajärjestelmässä. Luvun lopussa arvioidaan tutkimuksen merkitystä, luotettavuutta ja rajoitteita sekä annetaan ehdotuksia jatkotutkimusaiheiksi.

9.1 Tekoälyn omaksuminen TOE-mallin mukaan

Teemahaastattelussa pyrittiin selvittämään tekoälyn teknologioiden omaksumista ja ajatuksia niiden hyödyntämismahdollisuuksista. Seuraavissa alaluvuissa tarkastellaan tekoälyn omaksumista teknologian, organisaation ja ympäristön näkökulmista. TOE-mallin avulla pyritään varmistamaan, että aineiston analyysi ja johtopäätökset kattavat laajan ilmiön eri ulottuvuudet.

9.1.1 Teknologian näkökulma

Aiempien tutkimusten mukaan tekoälyn hyödyntämisen esteenä on ollut tarvittavan osaamisen puute (Chui & Malholtra, 2018). Haastatteluvastauksissa nousi esiin tekoälyn menetelmien erilaisuus perinteisiin järjestelmäkehitysmenetelmiin verrattuna. Teemahaastattelujen merkittävin havainto liittyikin juuri tekoälyn teknologioiden omaksumisen vaikeuteen perinteiseen järjestelmäkehitykseen verrattuna. Uusien teknologioiden käyttöönotto on aina ollut vaatimus järjestelmäkehityksessä. IT-alan koulutuksen ja työkokemuksen avulla on tavallista omaksua uusia ohjelmointikieliä ja sovelluskehityksiä. Perinteisessä järjestelmäkehityksessä yhden ohjelmointikielen hallinta auttaa uuden teknologian omaksumisessa. Kuitenkin tekoälyn teknologioiden erilaisuuden vuoksi ei samanlaista uuden teknologian omaksumista ollut nähtävissä haastatteluvastaus-

ten perusteella. Vaikka tekoäly, koneoppiminen ja syväoppiminen liitetään tietojenkäsittelytieteen tutkimusalueisiin, ei tietojenkäsittelytieteen tai tietotekniikan koulutus antanut valmiuksia näiden teknologioiden omaksumiseen. Datatieteen opiskelussa taas huomio on datalähtöisyydessä, tietojenlouhinnassa, koneoppimisessa ja tilastotieteessä, jolloin valmiudet tekoälyn menetelmien hyödyntämiseen ovat erilaiset. (Tekoälyn perusteet, 2019.) Kurssitarjonnan monipuolistuessa tilanne on muuttumassa tietojenkäsittelytieteen ja tietotekniikan opiskelussa, mutta myös työelämässä olevat tarvitsevat lisäkoulutusta datan käsittelyn ja koneoppimisen menetelmistä (Ailisto ym, 2019).

Tekoälyn teknologioita pidettiin niin erilaisena, että omatoimisen opiskelun ei odotettu tuovan riittävää osaamista teknologian hallintaan. Vaikuttaa siltä, että haastateltavan osallistuminen tekoälyn hyödyntämistä käsitteleville verkkokursseille ei vähentänyt ulkopuolisen asiantuntemuksen hankkimisen tarvetta. Päinvastoin kuin olisi voinut odottaa, mitä enemmän haastateltava oli omatoimisesti hankkinut koulutusta tekoälyn teknologioista, sitä tärkeämmäksi hän koki lisätuen tarpeen alkuvaiheessa. Tämä osoittaa, että omatoimisella opiskelulla on vaikea saavuttaa kokonaisvaltaista osaamista tekoälyn teknologioista, mutta opiskellessa havaitsee tekoälyn teknologioihin liittyvät haasteet. Koulutus on silti hyödyllistä, koska se lisää ymmärrystä teknologian mahdollisuuksista ja rajoituksista. Koulutuksen ansiosta haastateltava pystyi keskustelemaan täsmällisemmällä tasolla erilaisista tekoälyn sovelluskohteista. Tällöin haastateltavalla oli myös enemmän ideoita, joita voitaisiin soveltaa henkilöstö- ja palkanlaskentajärjestelmässä sekä sen palvelinympäristössä tai järjestelmän käyttöön liittyvissä prosesseissa. On huomioitava, että haastateltavat olivat osallistuneet korkeintaan yhdelle tai kahdelle yleisluontoiselle verkkokurssille, joten on mahdollista, että tarkemmin kohdennettu lisäkoulutus antaisi paremmat valmiudet tekoälyn teknologioiden käyttöönottoon.

Haastateltavat näkivät tekoälyn teknologiat uutena mahdollisuutena datan hyödyntämiseen. Henkilöstö- ja palkanlaskentajärjestelmässä on suuria määriä dataa eri sektoreilta, jolloin dataa on mahdollista käyttää moniin tarkoituksiin. Data on enimmäkseen määrämuotoista, jolloin sitä voidaan mahdollisesti saada helpommin koneoppimisen tarvitsemaan muotoon. Data tuo uusia mahdollisuuksia kehittää järjestelmään toimintoja, jotka eivät ole perinteisillä ohjelmointimenetelmillä mahdollisia. Toisaalta tekoälyn teknologioiden datalähtöisyyden koettiin hidastavan teknologian omaksumista. Uusien teknologioiden käyttöön tarvitaan uutta osaamista, ja myös työprosessit voivat vaatia uudelleen suunnittelua.

Henkilöstö- ja palkanlaskentajärjestelmä tekoälyn soveltamiskohteena lisää asiaan omat haasteensa. Palkanlaskennan vaatimus virheettömyyteen ja täsmällisyyteen asettaa rajoituksia tekoälyn teknologioiden hyödyntämiseen. Tekoälyä hyödyntäviä ratkaisuja ei voi helposti määritellä joko oikeiksi tai vääriksi - ennemminkin paremmiksi, huonommiksi, riittävän hyväiksi tai ei tarpeeksi hyväiksi. Perinteisellä ohjelmoinnilla ratkaistavat ongelmat ovat selkeämmin määriteltävissä, ja myös niiden toteutus sääntöihin perustuvalla ohjelmakoodilla on suoraviivaisempaa. Näin voidaan tietynä ajanhetkenä todetta,

että nyt kehitys on valmis ja toiminto on testauksessa todettu toimivan oikealla tavalla. Tekoälyn hyödyntämisessä voidaan päästä korkeintaan tilanteeseen, jossa ratkaisu toimii riittävän hyvällä tavalla (Holtel, 2016). Datalähtöisyys asettaa siten haasteita myös testaukselle, koska toisin kuin perinteisessä sääntöpohjaisessa ohjelmoinnissa, ei datalähtöisyydessä voida samalla tavalla varmistua toiminnan oikeellisuudesta.

Tässä pro gradu -tutkielmassa on käytetty organisaatiotason omaksumista kuvaavaa TOE-mallia varmistamaan organisaatioympäristössä tapahtuvan teknologian omaksumisen ilmiön eri ulottuvuudet. Kuitenkin tutkimuksen tuloksia voidaan tarkastella myös teknologian hyväksymisen teorioiden kautta. TAM-teorian teknologian hyväksymiseen vaikuttavat tekijät: havaittu hyödyllisyys ja havaittu helppokäyttöisyys (Davis, 1985) nousivat esiin haastatteluvastauksissa. Haastateltavat kuvaavat tekoälyn teknologioiden hyödyllisyyttä, mutta vielä enemmän vastauksissa painottui teknologian käyttöönoton vaikeus ja osaamisen puute. Haastateltavat olivat kiinnostuneita tekoälyn teknologioista ja moni oli hankkinut omatoimisesti lisää tietoa verkkokurssien avulla. Haastateltavat ilmaisivat myös kiinnostuksen uuden oppimisen ja valmiuden uusiin haasteisiin. Haastateltavien asenne tekoälyn teknologioita kohtaan oli hyväksyvä, mutta tekoälyn teknologioihin liittyvä korkea aloittamiskynnys on hidastanut käyttöönottoa.

Jos haastatteluvastauksia tarkastellaan DOI-teorian mukaan teknologian omaksumisprosessin näkökulmasta, voidaan organisaation arvioida olevan suostutteluvaiheen ja käyttöönottovaiheen välimaastossa (Rogers, 1995). Suostutteluvaiheessa tekoälyn teknologiat on hyväksytty ja niiden on todettu tuovan uusia mahdollisuuksia perinteisen järjestelmäkehityksen tueksi. Kuitenkin havaittuja hyötyjä enemmän omaksumiseen on vaikuttanut tekoälyn teknologioiden havaitseminen vaikeasti opittaviksi ja hyödynnettäviksi, jos aiempaa kokemusta teknologioista ei ole.

9.1.2 Organisaation näkökulma

Tekoälyn hyödyntäminen on uutta ja yksilöllistä kaikille organisaatioille. Ei ole olemassa valmiita kaikille toimivia ratkaisuja, vaan jokaisen organisaation on suunniteltava ja toteutettava omaan organisaatioon sopivat menetelmät. (Holtel, 2016.) MGI:n tutkimuksen vastaajista 43 % nosti tekoälystrategian puutteen suurimmaksi esteeksi tekoälyn omaksumiseen organisaatiossa (Chui & Malholtra, 2018). Samalla tavalla myös tässä teemahaastattelussa nousi esiin yhä uudestaan ajatus, että omaksumisen esteenä on epätietoisuus siitä, mitä organisaatiossa halutaan tehdä, ja mitkä ovat ne ongelmat, joita tekoälyn tai koneoppimisen keinoin haluttaisiin ratkaista. Organisaation täytyy muodostaa yhteinen näkemys ongelmasta ja myös yhteinen sitoumus ratkaisuihin (Holtel, 2016).

Aiempien tutkimusten mukaan organisaation koko on vaikuttanut tekoälyn teknologioiden omaksumiseen ja suuremmat organisaatiot ovat useammin olleet aikaisia omaksujia (Bughin ym., 2017). Vastaavasti haastateltavat kokivat, että organisaation kuuluminen isompaan konserniin luo yhteistyön mahdolli-

suuksia, jotka mahdollistavat tiedon ja hyväksi todettujen menetelmien leviämisen eri organisaatioiden välillä. Suuressa organisaatiossa resurssit koulutukseen, rekrytointiin tai alihankintaan voivat olla myös paremmat kuin pienyrityksessä.

Yritysjohdon tuen merkitys on aiemmissa tutkimuksissa nähty merkittäväksi tekijäksi tekoälyn omaksumisessa (Bughin ym., 2017). Kuten aiemmin todettiin, tekoälyn teknologioiden omaksumisen erilaisuus perinteisiin järjestelmäkehityksen menetelmiin verrattuna täytyy huomioida resursseissa. Vaikka perinteisen järjestelmäkehityksen teknologioita voidaan omaksua oman työn ohessa, haastatteluvastausten perusteella tekoälyn soveltamisessa ei ollut odotettavissa vastaavaa. Tekoälyn teknologioiden datalähtöisyys, koneoppimisen matemaattiset mallit ja tilastollisten menetelmien ymmärtäminen eivät ole vastaavanlainen asia kuin siirtyminen esimerkiksi uuden ohjelmointikielen tai sovelluskehityksen käyttöön. Kyse ei ole pelkästään ohjelmoinnista, vaan myös datan käsittelytaidot ja matemaattisten mallien ymmärtäminen on merkityksellistä toteutuksen onnistumisen kannalta.

Haastateltavat kokivat projektimuotoisuuden soveltuvan parhaiten kehitystyön organisointimuodoksi, koska projektin odotettiin tuovan kehityshankkeelle sen tarvitsemat reunaehdot sisältäen aikataulun, budjetin ja etenemisen seurannan. Haastateltavat totesivat, että projektin aikataulu, laajuus ja sille asetetut tavoitteet vaikuttavat tuen tarpeeseen projektin alkuvaiheessa. Jos tavoitteet eivät ole kovin korkeat ja aikaa on runsaasti käytettävissä eli kyseessä on lähinnä ammatilliseen kehittymiseen tähtäävä projekti, voidaan omin voiminkin lähteä liikkeelle. Toisaalta, jos tavoitteena olisi saada melko ripeällä aikataululla asiakkaille toimitettava tuote, pidettiin ulkopuolisen osaamisen hankkimista välttämättömänä. Organisaation osaamistason nosto nähtiin tärkeäksi koko henkilöstölle, vaikka ei osallistuisi projektiin. Yleiskoulutus tekoälyn teknologioista tulisi olla tarjolla kaikille, koska tekoälyn teknologioiden hyödyntäminen ei ole yhden tiimin sisäinen asia, vaan aiempien tutkimusten mukaan se on useimmiten tiimien rajoja ylittävää toimintaa (Bughin ym., 2017).

Organisaation osaamistason nosto nähtiin mahdolliseksi myös rekrytoimalla henkilö tai henkilöitä, joilla on aiempaa kokemusta tai tekemällä yhteistyötä tekoälyyn keskittyneen yrityksen kanssa. Ulkopuolinen tuki koettiin tärkeäksi teknologian omaksumista nopeuttavana tekijäksi, jotta kaikkea ei tarvitse opetella yrityksen ja erehdyksen kautta. Yksimielisyys vallitsi kuitenkin siinä, että koko kehityksen ulkoistamista organisaation ulkopuolelle ei pidetty hyvänä, koska jatkossa ylläpito vaatii kuitenkin osaamista. Tulevaisuudessa uusien projektien kanssa oltaisiin aina riippuvaisia ulkopuolisista henkilöistä, ellei siten ole tietoinen päätös hankkia jatkossakin kehitys ja ylläpito organisaation ulkopuolelta. Optimointi- ja koneoppimisprojekteissa mukana ollut Ollila (2019) arvioi oman tekemisen ja ulkopuolisen toteutuksen eroavaisuuksia seuraavasti:

Omin voimin tekemisessä on se hyvä puoli, että kun te ymmärrätte liiketoiminnan tosi hyvin, teidän on nopeampi arvioida, mikä on se kehityspolku, jota kannattaa lähteä kulkemaan. Sit se ite mallin rakentaminen, se voi olla aika vaikeeta. Siinä kyllä auttaa, että on joku, jolla on kokemusta vastaavista. (Ollila, 2019.)

Holtel (2016) kehottaa pyrkimään tekoälyn sovellusten kehittämisessä kokeilemaan nopeita kehityssyklejä. Nopeasti todettavissa olevat onnistumiset ja epäonnistumiset lisäävät ymmärrystä menetelmistä ja voivat avata näkökulmia uusille mahdollisuuksille. (Holtel, 2016.) On parempi tehdä useita lyhytkestoisia kokeiluja tai prototyyppejä, joilla voidaan jo aikaisessa vaiheessa arvioida toteutuksen onnistumista, kuin rakentaa pitkään täydellisesti suunniteltua yksittäistä ratkaisua (Bughin ym., 2017). Samalla tavalla myös haastateltavat korostivat ketterän kehityksen ja prototyypin valmistamisen vähentävän kehitystyöhön liittyviä riskejä. Tästä huolimatta pienemmissäkin kokeiluissa datan on oltava kunnossa, jotta voidaan luotettavasti arvioida sovelluksen toimivuutta (Ollila, 2019). Prototyyppejä ei voida kuitenkaan arvioida testiympäristössä täydellisesti, vaan vasta todellisessa ympäristössä nähdään lopullinen tulos (Holtel, 2016).

9.1.3 Ympäristön näkökulma

Tekoälyn vaikutusta on verrattu höyrykoneen keksimiseen 1700-luvulla. Höyrykoneen keksimisen vaikutus oli niin merkittävä, että yritykset eivät voineet jättää sitä huomioimatta. Organisaatiot eivät nytkään voi jättää tekoälyä huomioimatta, vaan ennemminkin organisaation on ratkaistava suhde tekoälyyn ja pohtia miten organisaatio voisi hyötyä siitä parhaiten. (Holtel, 2016.)

Tekoälyn soveltamisessa ei ole helppoa ennakoida hyötyjä ja ongelmakohtia, koska tekoälyn menetelmät eivät ole entuudestaan tuttuja. Holtel (2016) suosittelee ottamaan mukaan kaikki osapuolet, joihin tekoälyn sovellus voi vaikuttaa joko positiivisesti tai negatiivisesti. Eri osapuolten osallistuminen auttaa tuomaan esiin mahdollisia ongelmakohtia, vaikka kaikkien ongelmien ennustaminen voikin olla mahdotonta. (Holtel, 2016.) Haastateltavat toivatkin esiin huolen, että tarvitaan laaja ymmärrys tekoälyn sovelluksen kohteesta, jotta se olisi myös asiakkaiden mielestä hyödyllinen. Asiakkaiden näkemyksiä olisi hyvä tiedustella kyselyillä tai haastatteluilla. Haastateltavat toivat myös esiin aiemmat hyvät kokemukset yhdessä asiakkaiden kanssa tehdystä kehitystyöstä, joten olisi luontevaa tehdä yhteistyötä myös tekoälyn teknologioiden soveltamisessa.

Organisaatioiden päätöksentekoon vaikuttavat myös asiakkaiden odotukset ja kilpailijoiden tekemät toimet. Asiakkaiden robottihankkeet osoittavat, että on kiinnostusta uusia teknologioita kohtaan ja myös tarvetta toimintojen tehostamiseen. Robottihankkeet voivatkin olla ensiaskel uusiin teknologioihin, ja vähitellen asiakkaiden odotukset voivat kasvaa myös henkilöstö- ja palkanlaskentajärjestelmään liittyvän tekoälysovelluksen kehittämiseen. Yhteistyössä tekeminen voikin ratkaista monia avoimuuteen ja eettisiin näkökohtiin liittyviä kysymyksiä, joita tekoälyn teknologioihin voi liittyä. Tiedosta saatavat hyödyt voivat olla motivaationa yhteiselle kehittämiselle ja tietojen jakamiselle.

Yleinen keskustelu tekoälyn ympärillä on ollut viime vuosina runsasta. Tekoäly on käsitteenä suhteellisen laaja, ja sen määrittely yksikäsitteisesti lienee mahdotonta. Siksi organisaationkin voi olla haastavaa hahmottaa esimerkiksi

julkisuudessa käydystä tekoälykeskustelusta, mitä tekoälyllä tarkoitetaan ja miten markkinointitermit eroavat käytännön ratkaisuista. Ei ole järkevää mennä mukaan kehitykseen pelkästään sen takia, että se on muodikasta tällä hetkellä. Kuitenkaan tekoälyä ei voi jättää huomioimatta organisaatioissa, vaan on avoimin mielin luotava omaan organisaation sopiva tekoälystrategia. Jonkin todellisen tarpeen ratkaisu, johon juuri tekoälyn teknologiat ovat oikea menetelmä, voi tuoda organisaatiolle merkittävän kilpailuedun.

Yritysten, tutkimuslaitosten ja yliopistojen välinen yhteistyö on kirjallisuudessa nähty tärkeäksi organisaatioiden kilpailukyvyn kannalta (Ailisto ym., 2019). Kuten aiemmin on mainittu, osaamisen puute on todettu olevan esteenä tekoälyn hyödyntämiselle. Vaikka osa haastateltavista oli osallistunut tekoälyn teknologioihin liittyville verkkokursseille, omaan työhön soveltuvia valmiuksia kursseista oli vaikea saada. Tarvitaankin täydennyskoulutusta, joka pystyy vastaamaan organisaatioiden ja IT-alan asiantuntijoiden tarpeisiin.

9.2 Tekoälyn teknologioiden hyödyntäminen henkilöstö- ja palkanlaskentajärjestelmässä

Tässä alaluvussa analysoidaan haastatteluvastauksia tekoälyn hyödyntämisestä henkilöstö- ja palkanlaskentajärjestelmässä. Haastatteluteeman tarkoituksena oli tunnistaa ongelmakohtia, joissa tekoälyn tai koneoppimisen hyödyntäminen olisi mahdollista. Koneoppimisen menetelmät ovat mukana useimmissa tekoälyn sovelluksissa, koska oppiminen olemassa olevasta datasta on merkittävä tekoälyn ominaispiirre. Koneoppimisen lisäksi neuroverkot ja syväoppiminen ovat myös tärkeät menetelmät tekoälysovellusten oppimisessa.

Kuten koneoppimista käsittelevässä luvussa kaksi todettiin, koneoppimista tarvitaan kahden pääsyyn vuoksi: ongelma on monimutkainen ja sen takia hyvin vaikeasti ohjelmoitavissa tai on tarve, että ohjelma mukautuu aiemmasta käytöstä syntyneen datan perusteella (Shalev-Shwartz & Ben-David, 2014). Haastateltavien löytämät ongelmakohdat ja niiden ratkaisut osuivat myöskin näihin kahteen tarpeeseen. Kuitenkaan vastauksia ei voinut mekaanisesti jakaa näihin kahteen ryhmään, vaan useimmissa ongelmatilanteissa ja niiden ratkaisuissa oli nähtävissä elementtejä molemmista ryhmistä.

Vaikeasti perinteisin järjestelmäkehityksen keinoin ohjelmoitaviksi ongelmakohdiksi tunnistettiin toimintoja, jotka vievät paljon käyttäjien, kehityksen tai ylläpidon resursseja. Aikaa vievät toiminnot ovat usein myös monimutkaisia ihmisen tekemiä toimintoketjuja, joiden automatisointi olisi perinteisin ohjelmointikeinoin vaikeasti toteutettavissa. Toisena vaikeasti perinteisin menetelmin ohjelmoitavana alueena pidettiin suuria datamassoja, joita ihmisen on vaikea tai mahdotonta hahmottaa kokonaisuudessaan. Samalla tavalla suurten datamassojen osien keskinäisten riippuvuuksien tulkinta on yleensä mahdotonta.

Tarve ohjelman oppimiselle ja mukautumiselle aiemman käytön perusteella oli ongelmakohtien ryhmä, johon haastateltavat pohtivat esimerkiksi toistuvien virhekorjauksien oppimista tai käyttöliittymän mukautumista aiemman käytön mukaisesti. Ongelmia, joiden perimmäinen syy on oppimisen tarve, ei haastattelujen aikana noussut esille yhtä paljon kuin ensimmäiseen ryhmään liittyviä. Syitä ideoiden vähemmälle määrälle on vaikea sanoa tarkasti, mutta mahdollisena selityksenä voisi olla henkilöstö- ja palkanlaskentajärjestelmän toiminnan luonne tekoälyn soveltamiskohteena. Sovelluskohde on luonteeltaan tarkkuuteen ja virheettömyyteen tähtäävä, jolloin mukautuminen aiemman perusteella voisi sisältää riskejä. Sääntöpohjaisen järjestelmän toiminta on helpommin ennakoitavissa ja valvottavissa.

Kuten aiemmasta teemahaastatteluaiaineiston esittelyä käsittelevästä luvusta voidaan todeta, haastateltavat havaitsivat monia ongelmakohtia jaideoivat runsaasti erilaisia mahdollisuuksia tekoälyn teknologioiden hyödyntämiseen. Yksi yleisimmin mainituista ongelmista oli palkanlaskennan virheettömyyden varmistamisen vaikeus ja sen työllistävyys. Haastateltavat olivat havainneet eri tilanteita, joissa palkanlaskija käyttää aikaa virheiden etsimiseen ja korjaamiseen. Yhdeksi ongelmakohdaksi mainittiin palkanlaskenta-aineiston oikeellisuuden tarkastaminen, joka manuaalisena työnä vie runsaasti palkanlaskijan työaikaa. Tarkastamiseen ei välttämättä ole pätevää tapaa, jolla voisi täysin varmistua oikeellisuudesta. Ohjelmistorobotiikan kokeilut palkanlaskenta-aineiston oikeellisuuden tarkistamiseen kertovat, että kyseessä on todellinen ongelma, johon on yritetty etsittyä ratkaisua (Hyytiäinen, 2018).

Ongelmien ratkaisussa on hyvä miettiä, kuinka hyvin ne olisivat ratkaistavissa perinteisen järjestelmäkehityksen menetelmin. Jos ongelman ratkaisu pystytään määrittelemään sääntöpohjaisesti, vakiintuneet data-analytiikkaratkaisut lienevät turvallisin ja nopein ratkaisu (Ollila, 2019). Virheiden tarkistuksessa voidaan tarkastella henkilöä ja hänen palkkahistoriaansa sekä arvioida, poikkeako uusi havainto merkittävästi aiemmista havainnoista. Tietoja voidaan tarkastella myös kustannuspaikkatasolla tai yritystasolla ja tarkastella, löytyykö aineistosta yksittäisiä poikkeavia havaintoja. Tähän voisi jo perinteisin järjestelmäkehityksen keinoin suunnitella ratkaisun, joka tarkastaa näitä tietoja. Suuremmat poikkeamat aiempiin havaintoihin verrattuna nousisivat tarkastettavalle listalle, jolloin palkanlaskija voisi keksittyä pienempään määrään tarkastettavia henkilöitä koko palkanlaskenta-aineiston sijasta. Olisi huomioitava, että palkanmaksuun liittyy tavallisia vaihteluita, kuten lomarahoa tai vuorolisien maksua, joita ei saisi tulkita poikkeaviksi havainnoiksi.

Toisaalta isojen datamäärien analysointi voisi soveltua myös tekoälyn tai koneoppimisen hyödyntämisellä ratkaistavaksi. Aiempien tutkimusten mukaan tekoälyä on käytetty havaitsemaan poikkeamia palkanlaskennassa tai kirjanpidossa (Cabral & Oliveira, 2010). Jos palkanlaskenta-aineiston tarkistuksia tarvitaan edellä kuvattua tarkemmalla tasolla, alkaa olla jo vaikea tehdä sääntöpohjaista ohjelmakoodia, joka huomioisi normaalit vaihtelut. Koneoppimisen menetelmin sovelluksen on mahdollista oppia havaitsemaan poikkeamat, jos oppimiseen on tarjolla riittävästi dataa normaaleista ja poikkeavista tilanteista.

Tekoälyn sovellus vähentäisi palkanlaskijoiden tarkastuksiin käyttämää aikaa, jos järjestelmä pystyisi antamaan arvion palkanlaskennan oikeellisuudesta.

Toisena merkittävänä ryhmänä tekoälyn sovelluskohteista haastateltavat tunnistivat henkilöstö- ja palkanlaskentajärjestelmän tiedot arvokkaina datalähteinä, joita ei tällä hetkellä hyödynnetä. Aiemmissä tutkimuksissa henkilöstöhallinnon data on havaittu kiinnostavaksi kohteeksi tiedonlouhinnalle (Strohmeier & Piazza, 2013). Haastateltavat kehittivät uusia toimintoja tai tuotteita olemassa olevan datan pohjalta. Innovaatioiden tarkoituksena oli tehdä erilaisia analyysejä tai ennusteita olemassa olevasta datasta henkilöstöhallinnon ja organisaation päätöksenteon tueksi. Raporteilla voidaan saada tietoa menneestä ajasta, mutta voisi olla hyödyllistä saada ennuste myös tulevista. Haastateltavat mainitsivat hyödyllisiksi tiedoiksi esimerkiksi henkilöstö- ja palkkakulujen suunnan tulevaisuudessa pohjautuen aiempaan dataan. Resurssien optimoinnin mahdollisuus nostettiin myös esiin haastatteluvastauksissa. Aikaisempien vuosien poissaolojen määrä, loma-ajankohdat ja koulujen loma-ajat voisivat auttaa ennustamaan henkilöstöresurssien tarvetta. Hyvissä ajoin sovittuihin sijaisuuksiin työvoiman saanti on helpompaa, joten asialla on erityisesti merkitystä tilanteissa, joissa työntekijöistä on pulaa. Analyysit ja ennusteet ovat vaikeasti ohjelmoitavissa perinteisin menetelmin, mutta tiedonlouhinnan avulla suurista datamassoista voisi löytyä riippuvuuksia eri asioiden välillä.

Strateginen henkilöstöjohtaminen tarvitsee tuekseen dataan perustuvaa tietoa (Strohmeier & Piazza, 2013). Aiemmissä tutkimuksissa on mainintoja tekoälyn teknologioiden käytöstä luomaan ennustavia malleja henkilöstön palkkauksesta ja vaihtuvuudesta. Asiakkaat ovat luovuttaneet palkanlaskennan tietoja mallintamista varten ja sen vastineeksi ovat saaneet käyttöön ennustavat mallit ja vertailutietoja saman toimialan organisaatiosta (Tambe, Cappelli & Yakubovich, 2019.) Myös haastatteluissa nostettiin esiin ajatus, voitaisiinko mallien avulla arvioida esimerkiksi palkkauksen tasa-arvoisuutta ja kilpailukykyisyyttä sekä henkilöstön vaihtuvuutta vastaaviin toimialoihin verrattuna.

Nykyiselläänkin on jo varhaisen tuen palveluita, mutta haastateltavat pohtivat, olisiko datasta löydettävissä jo aiemmin merkkejä, jolloin työhyvinvointitoimenpiteitä voitaisiin kohdistaa oikeisiin yksiköihin. Ennaltaehkäisevä vaikuttaminen olisi tehokkaampaa kuin reagoiminen vasta sen jälkeen, kun kustannuksia on jo syntynyt. Haastateltavat pohtivat myös, voisiko datasta löytyä merkkejä, jotka ennustavat jotain kiinnostavaa asiaa. Olisi mahdollista tarkastella tiettyä toimialaa, jossa organisaatiot ovat riittävän samankaltaisia ja opettamista varten on olemassa havaintoja tapauksista, joille on tapahtunut ennustettava asia. Ennustavan mallin rakentaminen on mahdollista, jos on muuttujia, joiden voidaan olettaa vaikuttavan ennustettavaan suureeseen sekä mittaustuloksia muuttujista ja ennustettavasta suureesta (Ollila, 2019).

Chatbotit ovat olleet yleisimmin kokeiltujen tekoälyn sovellusten joukossa (Kääriäinen ym., 2018). Haastateltavat pohtivat myös chatbotin hyötyjä henkilöstö- ja palkanlaskentajärjestelmän asiakaspalvelun ja -tuen avuksi. Chatbotin käyttö voisi tuoda asiakkaalle nopeasti avun jo tunnettuihin ongelmiin tai auttaa tunnistamaan asiakkaan ongelmatilanteita, jolloin selvittely voidaan ohjata

oikealle asiantuntijalle. Chatbot voisi mahdollisesti oppia ratkaisemaan helpoimpia tapauksia, jolloin asiantuntijat voisivat keskittyä haastavimpien tilanteiden selvittämiseen. Toisaalta kirjallisuudessa mainitaan myös esimerkkejä, joissa chatbotin opettaminen on ollut vaikeampaa kuin etukäteen on osattu ajatella (Kääriäinen ym., 2018).

Muutamassa haastattelussa mainittiin myös tekoälyn teknologioiden hyödyntämisen mahdollisuus järjestelmän ylläpidossa. Tekoälyn sovelluskohteita voisi löytyä palvelinpuolen ratkaisuihin tai tietoturvan lisäämiseen. Ylläpitoon liittyvät kohteet ovat varsinaisen henkilöstö- ja palkanlaskentajärjestelmän sisällön ulkopuolella, joten näihin saattaisi parhaiten löytyä myös valmiita ratkaisuja.

Yhteenvedona voidaan todeta, että olemassa oleva data tarjoaa monia mahdollisuuksia tekoälyn teknologioiden hyödyntämiseen. Tärkeää kuitenkin on miettiä asiaa asiakaslähtöisesti, koska asiakas voi arvostaa eri asioita kuin esimerkiksi järjestelmän kehittäjä. Asiakkaiden mielipidettä tulisi kysyä ja pyrkiä löytämään sovelluskohde, joka tuo todellista lisäarvoa asiakkaille. Tekoäly on aina ratkaisu johonkin ongelmaan ja ongelman pitää olla olemassa ennen ratkaisua. On myös hyvä arvioida, ovatko juuri tekoälyn teknologiat paras valinta ongelmanratkaisuun vai voidaanko ongelma ratkaista perinteisillä menetelmillä.

9.3 Tutkimuksen merkitys

Tästä pro gradu -tutkielmasta on oletettavasti eniten hyötyä kohdeorganisaatiolle. Kirjallisuuskatsauksessa tarkasteltiin tekoälyn teknologioita, IT:n omaksumisen teorioita, tekoälyn omaksumista organisaatioissa sekä aiempia tutkimuksia tekoälyn hyödyntämisestä henkilöstö- ja palkanlaskentajärjestelmän konteksteissa. Tutkimuksen empiirisen osan teemahaastatteluista saatiin käsitys kohdeorganisaation tekoälyn hyödyntämisen valmiuksista. Haastattelut antavat keinoja valmiuksien lisäämiseen ja tietoa siitä, miten tekoälyprojekti kannattaisi aloittaa. Haastattelujen aikana yhdeksän asiantuntijaa ideoi erilaisia vaihtoehtoja tekoälyn hyödyntämiseen henkilöstö- ja palkanlaskentajärjestelmässä. Haastateltavat tunnustivat ongelmakohtia, joita voitaisiin ratkaista tekoälyn menetelmin. Näistä ideoista on mahdollisuus valita jokin jatkokehitykseen tai jatkaa ideointia vielä eteenpäin. Pro gradu -tutkielman toivotaan selkiyttävän tekoälyn datalähtöistä lähestymistapaa ongelmanratkaisukeinona ja auttaa tunnistamaan kohteita, joihin tekoälyn menetelmät parhaiten sopivat.

Pro gradu -tutkielma tuo uutta tietoa henkilöstö- ja palkanlaskentajärjestelmän kehitykseen osallistuvien henkilöiden näkemyksistä tekoälyn omaksumiseen teknologian, organisaation ja ympäristön näkökulmista. Kokemuksen puute tekoälyn teknologioiden hyödyntämisessä luo tarpeen osaamistason nostamiseen koulutuksella, rekrytoinnilla tai alihankinnalla. Mahdollisesti jopa kaikkien kolmen yhdistelmä voisi olla toimiva ratkaisu osaamisen lisäämiseksi organisaatiossa. Haastateltavat korostivat asiakaslähtöisyyden merkitystä kehittä-

tämisessä. Tärkeää olisikin saada asiakkaat mukaan suunnitteluun, jotta varmistetaan tekoälysovelluksen hyödyllisyys asiakkaiden näkökulmasta.

Yhtä organisaatiota koskevaa aineistoa ei voida yleistää laajemmin. Oletettavasti kuitenkin monissa muissakin IT-organisaatioissa joudutaan samalla tavalla ottamaan kantaa tekoälyyn ajankohtaisena teknologisenä ilmiönä. Kirjallisuuskatsauksen perusteella voidaan todeta, että monessa organisaatiossa mietitään, millä tavalla tekoälyn hyödyntäminen voisi sopia omaan liiketoimintaan. Tutkielmasta saa käsityksen tekoälyn hyödyntämisen nykyvalmiuksista, ja annetaan ehdotuksia valmiuksien lisäämiseen ja tekoälyprojektin organisointiin.

9.4 Tutkimuksen luotettavuus

Kaikessa tutkimustyössä on tärkeää arvioida tutkimuksen luotettavuutta. Luotettavuuden arvioinnissa käytetään reliabiliteetin ja validiteetin käsitteitä. Reliabiliteetilla tarkoitetaan tutkimuksen toistettavuutta eli saadaanko toistamalla tutkimus samanlaisena sama tutkimustulos kuin ensimmäisellä kerralla. Validiteetilla tarkoitetaan tutkimuksen pätevyyttä eli vastaako tutkimus esitettyihin tutkimuskysymyksiin. Voidaankin siis arvioida, ovatko tutkimuksen valitut menetelmät päteviä tutkimaan ilmiötä ja toisaalta, ovatko tutkimusaineistosta tehdyt johtopäätökset päteviä ja toistettavia. (Hirsjärvi & Hurme, 2011.)

Kvalitatiivinen tutkimus on reliabiliteetin ja validiteetin käsitteiden kannalta haasteellinen, koska kvalitatiivisella tutkimuksella tutkitaan monitahoista ilmiötä niiden omassa ympäristössään, jolloin täysin saman tutkimusasetelman järjestäminen uudestaan olisi mahdotonta. Kvalitatiivisen tutkimuksen aineisto onkin aikaan ja paikkaan sidonnainen (Hirsjärvi & Hurme, 2011.) Pro gradu -tutkielman tutkimusasetelmalla olisi mahdotonta saada myöhemmin täsmälleen samanlaisia vastauksia, koska sekä organisaation että henkilöstö- ja palanlaskentajärjestelmän tilanne muuttuu jatkuvasti.

Tutkimuksen pätevyyteen vaikuttaa tutkimusmenetelmän valinta ja miten hyvin menetelmällä voidaan tutkia tutkittavaa ilmiötä. Pro gradu -tutkielman menetelmäksi valittiin kvalitatiivinen tutkimus ja aineiston keruu teemahaastattelulla. Tutkijan olisi ollut vaikeaa lähestyä ilmiötä strukturoidun kyselylomakkeen kautta, koska vaarana olisi, että osa tutkittavasta ilmiöstä rajautuisi pois. Teemahaastattelu antaa syvällisemmän käsityksen tutkittavasta ilmiöstä. Kvalitatiivisessa tutkimuksessa ilmiön selvittämiseksi tarvittavien teemahaastattelujen lukumäärä ei ole tiedossa etukäteen. Saturaatiopisteeksi kutsutaan tilaa, jossa tutkija voi todeta, että uusien haastattelujen tekeminen ei enää tuota uutta tietoa. Tässä pro gradu -tutkielmassa teemahaastattelujen saturaatiopiste saavutettiin yhdeksännen haastattelun kohdalla.

Kvalitatiivisessa tutkimuksen luotettavuuden arvioinnissa on arvioitava myös tutkijan omaa roolia. Vaikka tutkijalla on pyrkimys objektiivisuuteen, on silti mahdollista tiedostamattaan vaikuttaa tuloksiin, koska kvalitatiivisessa tutkimuksessa tutkijan tulkinta on aineiston analyysissä suuressa roolissa. Pro gradu -tutkielman tekijä on osa tutkittavaa tiimiä, jolloin tästä kaksoisroolista

on voinut olla sekä haittaa että hyötyä. Hyödyllistä on ollut tutkimuskohteen etukäteistuntemus, jolloin haastattelujen keskustelukonteksti on ollut syväällisemmin ymmärrettävissä kuin täysin ulkopuolisen haastattelijan näkökulmasta olisi ollut. Tutkijan kaksoisroolista on voinut olla haittaa, jos se on vaikuttanut keskusteluun jollain tavalla, mutta tällaista ei ainakaan havaittu. Haastateltavat saivat vastata anonymisti, jolloin heillä on mahdollisuus puhua vapautuneesti. Sisällön analyysille oli tehty etukäteen selkeä suunnitelma, jolloin se vähentää tutkijan oman vaikutuksen mahdollisuutta ja lisää tutkimuksen luotettavuutta.

9.5 Tutkimuksen rajoitteet

Tutkimusasetelman rajoitteena voidaan pitää yhtä organisaatiota koskevaa aineistoa, joka kerättiin tietyssä ajankohtana, jolloin tutkimustuloksia ei voida yleistää laajemmin. Lisäämällä tutkimusasetelmaan toisen organisaation olisi ollut mahdollista saada kattavampi otanta, ja olisi ollut mahdollista yhdistellä ja vertailla tutkimustuloksia tutkimuksen luotettavuuden lisäämiseksi.

Toisena rajoitteena tutkimuksessa voidaan arvioida teemahaastattelun saturaatiopistettä toisen haastatteluteeman osalta, jonka tarkoituksena oli pohtia mahdollisuuksia tekoälyn hyödyntämiseen palkanlaskentajärjestelmässä. Uusien ideoiden saaminen ei saavuta samalla tavalla saturaatiopistettä, vaan toteuttamiskelpoisen innovaation voisi yhtä hyvin löytää sadannessa haastattelussa kuin ensimmäisen yhdeksän haastattelun aikana. Kuitenkin ongelmatilanteiden aihepiirit, joihin erilaisia tekoälyn soveltamisen ratkaisuvaihtoehtoja haettiin, alkoivat toistua eri haastatteluvastauksissa.

9.6 Jatkotutkimusaiheita

Tässä tutkimuksessa tekoälyn hyödyntämisen tarkastelussa suurin ääni annettiin järjestelmäkehitykseen osallistuville asiantuntijoille. Haastattelujen aikana useat haastateltavat mieltivät tekoälyn hyödyntämisen tarvetta asiakkaan näkökulmasta. Jatkotutkimusaiheena voisi olla asiakasnäkökulman saaminen aiheeseen. Voisi olla mielenkiintoista vertailla, miten tekoälyn hyödyntämisen näkökulma eroaa järjestelmäkehityksen ja asiakkaiden näkökulmista tarkasteltuna.

Tutkimuksessa havaittiin, että omatoimisesti suoritetuista tekoälyn teknologioiden verkkokursseista on saatu hyvin tietoa yleisellä tasolla, mutta käytännön työhön siirrettävän osaamisen saaminen on ollut vaikeaa. Onkin nähtävissä tarve täydennyskoulutukselle, josta saisi käytännön valmiuksia tekoälyprojektien aloittamiseen. Erilaisten kouluttautumismuotojen tutkiminen voisi olla aiheena jatkotutkimukselle, jossa pyrittäisiin löytämään toimivaa tapaa edistää tekoälyn teknologioiden omaksumista yksilö- ja organisaatiotasolla. Tarvittaisiin myös lisätutkimusta muista tekijöistä, jotka vaikuttavat tekoälyn

omaksumiseen, jotta voitaisiin madaltaa kuluja tekoälyprojektin aloittamiseen liittyvien vaatimusten ja olemassa olevien valmiuksien välillä. Useamman organisaation tarkastelulla saataisiin lisää tietoa eri toimialojen järjestelmäkehityksen valmiuksista tekoälyn omaksumiseen. Jatkotutkimusaiheena voisi olla tutkia tekoälyprojektin aloitusta ja seurata, miten tekoälyn omaksuminen muuttuu kokemuksen lisääntyessä.

Kirjallisuuskatsauksen mukaan tekoälyn sovelluksista on vielä suhteellisen vähän kokemusta, jolloin ei ole vielä riittävästi tietoa tekoälyyn tehtävien investointien kannattavuudesta. Organisaatioissa on epävarmuutta tekoälyn sopivuudesta oman organisaation tarpeisiin. Tarvittaisiin lisää tutkimusta tekoälyyn tehtävien investointien kannattavuudesta organisaatioiden päätöksenteon tueksi.

10 YHTEENVETO

Tämän pro gradu -tutkielman tutkimuskysymykset olivat: ”Mitkä tekijät vaikuttavat tekoälyn omaksumiseen organisaatiossa?” ja ”Miten tekoälyä voidaan hyödyntää henkilöstö- ja palkanlaskentajärjestelmässä?”. Tutkimuskysymyksiin vastattiin ensin kirjallisuuskatsauksen menetelmin. Kirjallisuuskatsauksen mukaan tekoälyn teknologioiden omaksumiseen vaikuttivat hidastavasti tekoälystrategian ja tarvittavan osaamisen puute organisaatioissa. Organisaation koko, ylimmän johdon tuki ja käytettävissä oleva data ovat myös tekoälyn omaksumiseen vaikuttavia tekijöitä.

Kirjallisuuskatsausta täydennettiin empiirisellä tutkimuksella, jossa käytettiin kvalitatiivista tutkimusmenetelmää. Aineistoa kerättiin teemahaastatteluilla, joihin osallistui yhdeksän henkilöstö- ja palkanlaskentajärjestelmän suunnittelun, kehityksen ja ylläpidon parissa työskentelevää IT-alan asiantuntijaa. Haastatteluteemoilla etsittiin vastauksia tekoälyn omaksumiseen vaikuttavista tekijöistä ja tarkasteltiin mahdollisuuksia tekoälyn hyödyntämiseen henkilöstö- ja palkanlaskentajärjestelmässä.

Teemahaastattelun tulokset vahvistivat aiempia kirjallisuuskatsauksessa löydettyjä tekoälyn teknologioiden omaksumiseen vaikuttavia tekijöitä. Tutkimuksen merkittävin löydös liittyi haastateltavien kokemukseen tekoälyn omaksumisen vaikeudesta perinteisen järjestelmäkehityksen menetelmiin verrattuna. Datalähtöisyys, matemaattiset mallit ja tilastolliset menetelmät tekevät tekoälyn teknologioista vaikeasti lähestyttäviä. IT-alan koulutus ja työkokemus eivät antaneet valmiuksia näiden teknologioiden omaksumiseen samalla tavalla kuin omaksutaan perinteisen järjestelmäkehityksen teknologiota. Haastateltavat, joilla oli eniten tietoa tekoälystä ja koneoppimisesta, pystyivät näkemään konkreettisempia sovelluskohteita tekoälylle tai koneoppimiselle. Omatoimisesti hankittu koulutus ei kuitenkaan lisännyt varmuutta tekoälyn tai koneoppimisen omaksumiseen, vaan haastateltavat näkivät selkeämmin epävarmuutta puuttuvien taitojen ja toteutuksen onnistumisen välillä. Tekoälyn omaksumisen haasteita voidaan madaltaa riittäväillä resursseilla ja nostamalla organisaation osaamistasoa koulutuksen, rekrytoinnin tai alihankinnan avulla.

Tekoälyn menetelmät ovat ongelmanratkaisukeino ja ratkaisun soveltuvuutta täytyy arvioida ongelman näkökulmasta tarkastellen. Tekoälyn menetelmät eivät sovellu kaikkiin tilanteisiin, joten onkin hyvä ensin miettiä, voidaanko ongelma ratkaista perinteisin menetelmin. Automaatio tarjoaa jo nyt monipuolisia mahdollisuuksia henkilöstö- ja palkanlaskennan järjestelmäkehitykseen, tästä huolimatta tutkimuksessa löydettiin uusia mahdollisuuksia hyödyntää kehityksessä tekoälyn teknologioita. Haastatteluvastauksissa korostui tarve tehdä kehitystyötä yhdessä asiakkaiden kanssa, jotta tekoälyn hyödyntämisellä ratkaistaisiin merkityksellisiä ongelmia.

Tekoälyn hyödyntäminen on tällä hetkellä monille organisaatioille ajankohtainen aihe. Tässä pro gradu -tutkielmassa tarkasteltiin yhden organisaation tekoälyn omaksumista IT-alan asiantuntijoiden näkökulmasta. Tarvitaan lisää tutkimusta tekoälyn omaksumiseen vaikuttavista tekijöistä ja omaksumista helpottavista keinoista organisaatioissa.

LÄHTEET

- van der Aalst, W. M. P., Bichler, M. & Heinzl, A. (2018). Robotic process automation. *Bus Inf Syst Eng* 60(4): 269–272.
- Aboelmaged, M. G. (2014). Predicting e-readiness at firm-level: An analysis of technological, organizational and environmental (TOE) effects on e-maintenance readiness in manufacturing firms. *International Journal of Information Management*, 34(5), 639–651.
- Ailisto, H. (toim.), Neuvonen, A., Nyman, H., Halén, M. & Seppälä, T. (2019). *Tekoälyn kokonaiskuva ja kansallinen osaamiskartoitus – loppuraportti*. Valtioneuvoston selvitys- ja tutkimustoiminnan julkaisusarja 4/2019.
- Alasuutari, P. (2011). *Laadullinen tutkimus 2.0* (4. uud. p.). Tampere: Vastapaino.
- Alpaydin, E. (2016). *Machine learning: the new AI*. MIT press.
- Alsheibani, S., Cheung, Y. & Messom, C. (2018). Artificial intelligence adoption: AI-readiness at firm-level. Teoksessa M. Tanabu, & D. Senoo (toim.), *Proceedings of PACIS2018: Pacific Asia Conference in Information Systems (PACIS) IL USA*: Association for Information Systems.
- Amazon Alexa. (2019). Amazon Alexa. Haettu 5.4.2019 osoitteesta <https://developer.amazon.com/alexa>
- Apple Siri. (2019). Apple Siri. Haettu 5.4.2019 osoitteesta <https://www.apple.com/siri/>
- Arria. (2019). Arria NLG. Haettu 16.2.2019 osoitteesta <https://www.arria.com/>
- Automated Insights. (2019). Natural Language Generation. Haettu 16.2.2019 osoitteesta <https://automatedinsights.com/>
- Baker, J. (2012). The technology–organization–environment framework. Teoksessa *Information systems theory* (s. 231–245). Springer, New York, NY.
- Basistech. (2019). Natural Language Processing. Haettu 12.3.2019 osoitteesta <https://www.basistech.com/natural-language-processing/>
- Brynjolfsson, E., & McAfee, A. (2012). *Race against the machine: How the digital revolution is accelerating innovation, driving productivity, and irreversibly transforming employment and the economy* (Research brief). MIT Sloan School of Management.

- Bughin, J., Hazan, E., Ramaswamy, S., Chui, M., Allas, T., Dahlström, P. & Trench, M. (2017). *Artificial Intelligence – The Next Digital Frontier?* McKinsey Global Institute.
- Burrell, J. (2016). How the machine ‘thinks’: Understanding opacity in machine learning algorithms. *Big Data & Society*, 3(1), 2053951715622512.
- Cabral, G. G. & Oliveira, A. L. (2010). A hybrid method for novelty detection in time series based on states transitions and swarm intelligence. Teoksessa *The 2010 International Joint Conference on Neural Networks (IJCNN)* (s. 1–8). IEEE.
- Campos, S. R., Fernandes, A. A., De Sousa, R. T., De Freitas, E. P., da Costa, J. P. C. L., Serrano, A. M. R. & Rodrigues, D. D. C. (2012). Ontologic audit trails mapping for detection of irregularities in payrolls. Teoksessa *2012 Fourth International Conference on Computational Aspects of Social Networks (CASoN)* (s. 339–344). IEEE.
- Chi, M. T. (1997). Quantifying qualitative analyses of verbal data: A practical guide. *The journal of the learning sciences*, 6(3), 271–315.
- Chowdhury, G. G. (2003). Natural language processing. *Annual review of information science and technology*, 37(1), 51–89.
- Chui, M. & Malholtra, S. (2018). *Notes from the AI frontier: AI adoption advances, but foundational barriers remain.* McKinsey Global Institute.
- Davenport, T. H., & Patil, D. J. (2012). Data scientist: The Sexiest Job of the 21st Century. *Harvard business review*, 90(5), 70–76.
- Davenport, T. H. (2016). Rise of the strategy machines. *MIT Sloan Management Review*, 58(1), 29.
- Davis, F. D. (1985). *A technology acceptance model for empirically testing new end-user information systems: Theory and results* (Väitöskirja). Massachusetts Institute of Technology.
- Davis, F. D., Bagozzi, R. P., & Warshaw, P. R. (1989). User acceptance of computer technology: a comparison of two theoretical models. *Management science*, 35(8), 982–1003.
- Danilewicz, D. (1997). How technology has changed the payroll function. *Management Accounting (USA)*, 78(12), S6–S6.
- Dey, I. (2005). *Qualitative data analysis: A user friendly guide for social scientists.* Routledge. Haettu 1.12.2019 osoitteesta https://www.fsnnetwork.org/sites/default/files/qualitative_data_analysis.pdf

- Graupe, D. (2013). *Principles of artificial neural networks* (3. painos). New Jersey: World Scientific.
- Hirsjärvi, S. & Hurme, H. T. (2011). *Tutkimushaastattelu – Teemahaastattelun teoria ja käytäntö*. Helsinki: Gaudeamus Helsinki University Press.
- Holtel, S. (2016). Artificial Intelligence Creates a Wicked Problem for the Enterprise. *Procedia Computer Science*, 99, 171–180.
- Hyytiäinen, J. (2018). *Prosessiselvitys palkkalaskelman tarkistamisesta KuntaPro Oy:lle* (Opinnäytetyö). Satakunnan ammattikorkeakoulu.
- Iacovou, C. L., Benbasat, I. & Dexter, A. S. (1995). Electronic data interchange and small organizations: adoption and impact of technology. *MIS quarterly*, 465–485.
- Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, 61(4), 577–586.
- Kaplan, J. (2016). *Artificial Intelligence: What everyone needs to know*. New York: Oxford University Press.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), 59–69.
- Kuan, K. K. & Chau, P. Y. (2001). A perception-based model for EDI adoption in small businesses using a technology–organization–environment framework. *Information & management*, 38(8), 507–521.
- Kääriäinen, J. (toim.), Aihkisalo, T., Halén, M., Holmström, H., Jurmu, P., Matinmikko, T., Seppälä, T., Tihinen, M. & Tirronen, J. (2018). *Ohjelmistorobotiikka ja tekoäly – soveltamisen askelmerkkejä*. Valtioneuvoston selvitys- ja tutkimustoiminnan julkaisusarja 65/2018.
- Lawler, J. J. & Elliot, R. (1996). Artificial intelligence in HRM: an experimental study of an expert system. *Journal of Management*, 22(1), 85–111.
- McAfee, A., & Brynjolfsson, E. (2012). Big data: the management revolution. *Harvard business review*, 90(10), 3–9.
- Markus, M. L. (2017). Datification, organizational strategy, and IS research: what's the score? *The Journal of Strategic Information Systems*, 26(3), 233–241.
- Mintzberg, H., & Waters, J. A. (1985). Of strategies, deliberate and emergent. *Strategic management journal*, 6(3), 257–272.
- Mullin, B. (2016, 19. lokakuuta). The Washington Post will use automation to help cover the election. Haettu 16.2.2019 osoitteesta

<https://www.poynter.org/tech-tools/2016/the-washington-post-will-use-automation-to-help-cover-the-election/>

- Myers, M. D. & Newman, M. (2007). The qualitative interview in IS research: Examining the craft. *Information and organization*, 17(1), 2–26.
- Narrative Science. (2019). Narrative Science Products. Haettu 16.2.2019 osoitteesta <https://narrativescience.com/products/>
- Okoli, C. & Schabram, K. (2010). A guide to conducting a systematic literature review of information systems research. *Sprouts: Working Papers on Information Systems*, 10(26).
- Ollila, J. (2019). Deputy CEO. Weoptit Oy. Haastattelu 29.5.2019.
- Oliveira, T. & Martins, M. F. (2010). Understanding e-business adoption across industries in European countries. *Industrial Management & Data Systems*, 110(9), 1337–1354.
- Oliveira, T. & Martins, M. F. (2011). Literature review of information technology adoption models at firm level. *Electronic Journal of Information Systems Evaluation*, 14(1), 110.
- Pan, M. J. & Jang, W. Y. (2008). Determinants of the adoption of enterprise resource planning within the technology-organization-environment framework: Taiwan's communications industry. *Journal of Computer information systems*, 48(3), 94–102.
- Perera, R. & Nand, P. (2017). Recent advances in natural language generation: A survey and classification of the empirical literature. *Computing and Informatics*, 36(1), 1–32.
- Radha, V. & Vimala, C. (2012). A review on speech recognition challenges and approaches. *World of Computer Science and Information Technology Journal (WCSIT)*, 2(1), 1–7.
- Ranjan, J., Goyal, D.P. & Ahson, S.I. (2008) Data mining techniques for better decisions in human resource management systems. *International Journal of Business Information Systems*, 3(5), 464–481.
- Ransbotham, S., Kiron, D., Gerbert, P., & Reeves, M. (2017). Reshaping Business With Artificial Intelligence: Closing the Gap Between Ambition and Action. *MIT Sloan Management Review*, 59(1).
- Regulation (EU) 2016/679 of the European Parliament and of the Council. Europa. Haettu 1.3.2019. osoitteesta <https://eur-lex.europa.eu/legal-content/FI/TXT/PDF/?uri=CELEX:02016R0679-20160504&from=EN>

- Rogers, E. M. (1995). *Diffusion of innovations*. Simon and Schuster.
- Russell, S. J. & Norvig, P. (2016). *Artificial intelligence: a modern approach*. Pearson Education Limited.
- Saarinen, M., Aholainen, J., Anttila, O., Jääskeläinen, R., Murto, J., Peltomäki, T., Salo, E., Siitonen, S., Korhonen, T., (2018). *Palkkahallinto*. Jatkuva julkaisu. Haettu 30.1.2019 osoitteesta <https://fokus.almatalent.fi/teos/EAJBFXCTEBAlma>
- Shalev-Shwartz, S., & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge university press.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G. & Dieleman, S. (2016). Mastering the game of Go with deep neural networks and tree search. *nature*, 529(7587), 484.
- Stone, P., Brooks, R., Brynjolfsson, E., Calo, R., Etzioni, O., Hager, G., ... & Leyton-Brown, K. (2016). *Artificial intelligence and life in 2030*. One Hundred Year Study on Artificial Intelligence: Report of the 2015–2016 Study Panel.
- Strohmeier, S., & Piazza, F. (2013). Domain driven data mining in human resource management: A review of current research. *Expert Systems with Applications*, 40(7), 2410–2420.
- Tambe, P., Cappelli, P. & Yakubovich, V. (2019). Artificial Intelligence in Human Resources Management: Challenges and a Path Forward. *California Management Review*, 61(4), 15–42.
- Tankard, C. (2016). What the GDPR means for businesses. *Network Security*, 2016(6), 5–8.
- Tekoälyn perusteet. (2019). Helsingin yliopisto. Verkkokurssi. Haettu 6.12.2019 osoitteesta <https://www.elementsofai.com/fi/>
- Thong, J. Y. (1999). An integrated model of information systems adoption in small businesses. *Journal of management information systems*, 15(4), 187–214.
- Tornatzky, L. G., Fleischer, M., & Chakrabarti, A. K. (1990). *The processes of technological innovation*. Issues in organization and management series. Lexington Books.
- Turing, A. (1950). Computing Machinery and Intelligence. *Mind*, 59(236), 433–460.
- Venkatesh, V., Morris, M. G., Davis, G. B. & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS quarterly*, 425–478.

- Venkatesh, V., Thong, J. Y. & Xu, X. (2012). Consumer acceptance and use of information technology: extending the unified theory of acceptance and use of technology. *MIS quarterly*, 36(1), 157–178.
- Visma. (2018). Palkanlaskennassa automaatio korvaa jo robotit - palkanlaskijan työ on muuttumassa pysyvästi. Haettu 28.1.2019 osoitteesta <https://media.visma.fi/pressreleases/palkanlaskennassa-automatio-korvaa-jo-robotit-palkanlaskijan-tyoe-on-pysyvaesti-muuttumassa-2687838>
- Witten, I. H., Frank, E., Hall, M. A. & Pal, C. J. (2016). *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann.
- Wohlin, C. (2014). Guidelines for snowballing in systematic literature studies and a replication in software engineering. Teoksessa *Proceedings of the 18th international conference on evaluation and assessment in software engineering* (s. 38). ACM.
- Zhu, K., Kraemer, K. & Xu, S. (2003). Electronic business adoption by European firms: a cross-country assessment of the facilitators and inhibitors. *European Journal of Information Systems*, 12(4), 251–268.
- Zhu, K. & Kraemer, K. L. (2005). Post-adoption variations in usage and value of e-business by organizations: cross-country evidence from the retail industry. *Information systems research*, 16(1), 61–84.

LIITE 1 TAUSTATIEDOT JA SUOSTUMUS TUTKIMUKSEEN

Nimi _____

Ikä < 25 26-35 36-45 46-55 56-65 > 65

Nimike _____

Peruskoulu / Toinen aste / Alempi korkeakoulututkinto / Ylempi korkeakoulututkinto

Koulutusala _____

Tekoälyyn liittyvä koulutus/kurssit

Datan käsittelyä tai tekoälyn hyödyntämistä edistävä osaaminen

Haastattelun tiedot ovat luottamuksellisia eikä yksittäisen vastaajan tietoja voi eritellä tuloksista. Osallistuminen haastatteluun on vapaaehtoista. Haastateltavalla on oikeus keskeyttää osallistuminen missä vaiheessa tahansa. Haastattelut nauhoitetaan ja Hanna Lemmetty käyttää vastauksia Jyväskylän yliopistossa tehtävässä Tietojärjestelmätieteen pro gradu -tutkielmassa.

Annan suostumuksen haastatteluun, haastattelun nauhoitukseen ja vastausten käyttämiseen pro gradu -tutkielmassa edellä mainittujen ehtojen mukaisesti:

Pvm

Allekirjoitus

Kiitos osallistumisesta!