



**TURUN
YLIOPISTO**
Kauppakorkeakoulu

Tekoäly rullaavan budjetoinnin ennusteissa

Koneoppimisen ja syväoppimisen hyödyntäminen rullaavan budjetoinnin ennusteissa

Laskentatoimen ja rahoituksen
kandidaatintutkielma

Laatija:
Kii Niemi

Ohjaaja:
KTT Oana Apostol

3.5.2024
Turku

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

Kandidutkielma

Oppiaine: Laskentatoimi ja rahoitus

Tekijä: Kii Niemi

Otsikko: Tekoäly rullaavan budjetoinnin ennusteissa – Koneoppimisen ja syväoppimisen hyödyntäminen rullaavan budjetoinnin ennusteissa

Ohjaaja: KTT Oana Apostol

Sivumäärä: 44 sivua

Päivämäärä: 3.5.2024

Digitalisaation myötä teknologian käyttö liiketoiminnassa on yleistynyt, ja tekoäly nykypäivän johtavana teknologiana luo jatkuvasti uusia mahdollisuuksia. Tekoäly on tehnyt läpimurtonsa viimeisten vuosien aikana, koska big datan lisääntyminen ja sitä myötä kiinnostus tekoälyä kohtaan on mahdollistanut tekoälyteknologioiden nopealle kehitykselle. Kehityksen myötä tekoälyn mahdolliset käyttökohteet ovat nousseet puheenaiheeksi.

Budjetointi on yrityksen taloushallinnon merkittävimpiä tehtäviä, ja se ohjaa koko yrityksen toimintaa. Perinteinen budjetointi on kuitenkin saanut osakseen paljon kritiikkiä sen toimivuudesta nykyajan epävarmoissa ympäristöissä, ja sen rinnalle on syntynyt uudempia budjetointitapoja. Etenkin rullaava budjetointi on yleistynyt perinteisen budjetoinnin kritiikin myötä joustavampana ja paremmin epävarmoihin ympäristöihin sopeutuvana menetelmänä.

Teknologian hyödyntäminen rullaavassa budjetoinnissa on nykypäivänä välttämätöntä, sillä ihminen ei voi enää kilpailla konetta vastaan. Tekoäly nykypäivän johtavana teknologiana voi tarjota helpotusta yritysten rullaavan budjetoinnin ennustamiseen nopeuttamalla ja tarkentamalla ennusteita.

Tutkimus toteutettiin kirjallisuuskatsauksena. Tutkimuksessa käsitellään tekoälyn ja budjetoinnin teoriaa kirjallisuuden pohjalta ennen kuin lähdetään tarkastelemaan tekoälyn käyttöä rullaavan budjetoinnin ennusteissa. Tarkasteltu kirjallisuus on alan tutkijoiden tuottamaa, ja kirjallisuutena on käytetty tieteellisiä artikkeleita sekä kirjoja. Tutkimuksen tavoitteena oli selvittää, miten tekoälyä ja etenkin sen olennaisia teknologioita koneoppimista ja syväoppimista voidaan hyödyntää rullaavan budjetoinnin ennusteissa.

Tekoälyn mahdollisuudet tutkielman perusteella liittyvät pääosin päätöksenteon tarkkuuden parantamiseen rullaavan budjetoinnin ennusteissa, rullaavien ennusteiden laatimisen nopeuttamiseen ja helpottumiseen sekä datan systemaattiseen ja tehokkaaseen läpikäyntiin ennustuksia laadittaessa. Koneoppimista voidaan etenkin hyödyntää jäsennellyn datan järjestelmissä ja uusien yhteyksien löytämisessä datasta, jos yritys haluaa säilyttää ennustuspäätökset ihmisen laatimina. Syväoppimisen todetaan olevan toimiva automatisoituna ennustusmenetelmänä, kun kyseessä on laajoja jäsentämättömiä datamääriä.

Tekoälyä on käsitelty kirjallisuudessa paljon, mutta tekoälyn käyttöä budjetoinnissa vain vähän, eikä kirjallisuutta ole lähes ollenkaan tekoälystä rullaavassa budjetoinnissa. Kirjallisuutta löytyy kuitenkin tekoälyn avulla ennustamisesta. Tutkielmassa on siis tarkasteltu eri tutkimuksia ja tehty niiden pohjalta johtopäätöksiä tekoälyn mahdollisesta käytöstä rullaavan budjetoinnin ennusteissa, mutta empiiristä tutkimusta sen käytöstä ei vielä ole. Tutkielma kannustaa lisätutkimukselle koska tekoäly kehittyy jatkuvasti ja tarvitaan empiiristä tutkimusta tekoälyn käytöstä juuri rullaavan budjetoinnin ennusteiden näkökulmasta.

Avainsanat: rullaava budjetointi, tekoäly, koneoppiminen, syväoppiminen, ennustaminen

SISÄLLYS

| | | |
|----------|--|-----------|
| 1 | Johdanto | 7 |
| 1.1 | Tutkielman tausta ja motivaatio | 7 |
| 1.2 | Tutkielman tavoite, rajaukset ja rakenne | 8 |
| 2 | Johdatus tekoälyyn | 11 |
| 2.1 | Tekoälyn määritelmä ja sen haasteita | 11 |
| 2.2 | Tekoälyn luokittelua | 12 |
| 2.3 | Tekoälyteknologioita | 13 |
| 2.3.1 | Koneoppiminen | 14 |
| 2.3.2 | Syväoppiminen | 15 |
| 3 | Budjetointi | 19 |
| 3.1 | Budjetoinnin määritelmä ja sen tehtävät | 19 |
| 3.2 | Perinteisen budjetoinnin kritiikki | 20 |
| 3.3 | Vaihtoehtoisia budjetointitapoja | 22 |
| 3.4 | Rullaava budjetointi | 23 |
| 4 | Tekoälyn käyttö rullaavan budjetoinnin ennusteissa | 26 |
| 4.1 | Tekoälyn käyttöönoton edellytyksiä | 26 |
| 4.2 | Tekoälyn mahdollisuudet rullaavan budjetoinnin ennusteissa | 28 |
| 4.2.1 | Koneoppiminen | 30 |
| 4.2.2 | Syväoppiminen | 31 |
| 4.2.3 | Koneoppivan ja syväoppivan ennustusmenetelmän vertailu kahden tutkimuksen kautta | 34 |
| 5 | Yhteenveto ja johtopäätökset | 38 |
| | Lähteet | 41 |

KUVAT

- Kuva 1 Havainnekuva koneoppimisesta ja syväoppimisestä tekoälyteknologioina
(tekijän itse tekemä kuva) 16
- Kuva 2 Malli yksinkertaisesta neuroverkosta (Kreutzer & Sirrenberg 2020, 5) 16
- Kuva 3 Erilaisia budjetointitapoja (Pellinen 2017, 69) 22

TAULUKOT

- Taulukko 1 Raamit tekoälyn onnistuneeseen implementointiin organisaatioissa
(Kaplan & Haenlein 2019a, 20) 28

1 Johdanto

1.1 Tutkielman tausta ja motivaatio

Tekoälystä (engl. Artificial Intelligence, AI) on viimeisten vuosikymmenten aikana tullut yksi maailman johtavista teknologioista, ja sen mahdollisuuksista käydään paljon keskustelua. Tekoälyn tutkimus aloitettiin kuitenkin varsinaisesti jo vuonna 1956, kun Dartmouthin yliopistossa järjestettiin tutkimus, jossa pyrittiin selvittämään koneen mahdollisuutta matkia älyä (McCarthy ym. 2006). Tekoälyä on siis alettu kehittämään jo lähes 70 vuotta sitten.

Tekoälyn kehitys on kiihtynyt viimeisten vuosikymmenten aikana, mikä on mahdollistanut tekoälysovellusten laajemman käyttöönoton, esimerkiksi suuren suosion saaneen ChatGPT:n. Duanin ym. (2019, 63) mukaan viime vuosina kasvanutta tekoälyn suosiota selittää tietokoneiden laskentatehon sekä big datan eli suurten datamäärien lisääntyminen, jonka ansiosta tekoäly on kasvanut nopeasti. Dwivedi ym. (2021, 2) mukaan lisäksi eri tekoälyteknologioiden kuten koneoppimisen ja syväoppimisen kehittyminen on mahdollistanut uusille tekoälyä hyödyntäville järjestelmille, ja sen vaikutukset voivat olla merkittäviä monilla aloilla. Koneoppiminen ja syväoppiminen ovat yleisiä tekoälyteknologioita, jotka hyödyntävät toiminnassaan algoritmeja¹ ja kykenevät datan tehokkaaseen prosessointiin. (Kufel ym. 2023, 1–2). Tekoälyn tuomien hyötyjen rinnalla se on myös yksi kiistellyimmistä aiheista, ja ymmärrys tekoälyn ja ihmisälän eroista ja yhtäläisyyksistä on vielä heikko (Korteling ym. 2021, 1).

Monet yritysten manuaaliset tehtävät pystyttiin korvaamaan koneilla jo teollisen vallankumouksen aikana. Nykypäivänä tekoäly tarjoaa vastaavan mahdollisuuden, sillä tekoälyn avulla voidaan korvata ihmisten suorittamia monimutkaisempia älyllisiä tehtäviä. (Dwivedi ym. 2021, 2.) Tekoälyn nousua muiden uusien teknologioiden rinnalla on kutsuttu jopa neljänneksi teolliseksi vallankumoukseksi (Syam & Sharma 2018, 135). Ensimmäinen teollinen vallankumous muutti ihmisten tekemän fyysisen liukuhihnatyön tehokkaammaksi teknologian avulla. Uuden tekoälyn mahdollistaman vallankumouksen myötä liiketoiminnan haastavimmatkin tehtävät voidaan yksinkertaistaa tai jopa automatisoida kokonaan. Tekoälyn kehitys näkyy jo esimerkiksi asiakaspalvelurobottien

¹ Algoritmi on annettu ohjauksen rakenne, joka toteuttaa tietyn tarkoituksen tietyin edellytyksin. (Hill 2016, 47)

lisääntymisenä, ja sen mahdollisuudet voivat olla merkittäviä myös muilla liiketoiminnan osa-alueilla kuten taloushallinnossa.

Yrityksen taloushallinnon tavoitteena on saada yritys toimimaan mahdollisimman kannattavasti. Budjetointi on taloushallinnon keskeisimpiä tehtäviä, ja sen avulla voidaan seurata yrityksen toiminnan kannattavuutta. (Pellinen 2017, 69.) Perinteinen budjetointi on ollut kuitenkin kiistanalaisena sen saaman kritiikin myötä (Asogwa & Etim 2017). Kritiikkiä perinteinen budjetointi on saanut muun muassa prosessin hitaudesta, liian harvoin tehdystä budjetoinnista sekä siitä, että perinteinen budjetointi rajoittaa reagointikykyä ja mahdollisuuksia muutokselle. Kritiikin myötä sen rinnalle on syntynyt uusia budjetointitapoja, joista yleisin on rullaava budjetointi (engl. rolling budget). Rullaavassa budjetoinnissa budjettiennusteita tehdään jatkuvasti, eikä vain kerran vuodessa, jolloin reagointi muutoksille on nopeampaa ja tarkempaa. (Neely ym. 2003.)

Rullaavien budjettien laatiminen vaatii jatkuvaa ennustamista, ja teknologian hyödyntäminen on välttämätöntä rullaavan budjetoinnin ennusteissa (Åkerberg 2017, 102). Tekoäly taas on nykypäivän johtavia teknologioita (Chen ym. 2023). Tämän takia tekoälyn hyödyntäminen rullaavassa budjetoinnissa ja etenkin sen ennusteissa on hyödyllinen tutkimuskohde. Tekoälyn tutkimus on ajankohtaista, sillä on tärkeää, että ymmärrys tekoälystä kasvaa, ja sen potentiaaliset käyttömahdollisuudet otetaan huomioon. Tekoälyn käyttö juuri rullaavan budjetoinnin ennusteissa on valittu tutkimuskohteeksi, koska rullaava budjetointi on yleistynyt budjetointikäytäntö ja budjetointi on taloushallinnon tärkeimpiä tehtäviä.

1.2 Tutkielman tavoite, rajaukset ja rakenne

Tutkielman tavoitteena on selvittää tekoälyn käyttömahdollisuuksia rullaavan budjetoinnin ennusteissa ennustusmenetelmänä ja osana ennustamista. Tutkielmassa tarkastelun pääkohteena ovat ennusteissa käytettävät tekoälyteknologiat koneoppiminen ja syväoppiminen. Tutkielmassa rullaavaa budjetointia tarkastellaan perinteisen budjetoinnin ja sen saaman kritiikin pohjalta.

Tutkielman tutkimuskysymykset ovat jaettu pääkysymykseen, ja sitä täydentäviin alakysymyksiin. Alakysymysten avulla pyritään vastaamaan pääkysymykseen. Tutkielman tutkimuskysymykset ovat:

1. Miten tekoälyä voidaan hyödyntää rullaavan budjetoinnin ennusteissa?

- a. Mitkä ovat tekoälyn käyttöönoton edellytykset?
- b. Mitkä ovat koneoppivan ja syväoppivan järjestelmän hyötyjen keskeiset erot rullaavan budjetoinnin ennusteissa?

Tutkielma toteutetaan kirjallisuuskatsauksena. Tutkielmassa hyödynnetään alan tieteellisiä artikkeleita, kirjoja ja tutkimuksia. Tutkielmassa käsitellään tekoälyn osa-alueita sekä big dataa, koska niitä voidaan pitää oleellisena tekoälyn toiminnan ja maailman teknologisen kehityksen kannalta. 2010-luvulla tekoäly on noussut suosioon yleiskäsitteenä, sillä tekoälyn eri osa-alueiden ymmärtäminen ja selittäminen on tullut haastavaksi, ellei jopa mahdottomaksi (Duan ym. 2019, 66). Tutkielmassa tekoälyn tarkastelu rullaavien budjettien ennusteissa rajataan koneoppimisen ja syväoppimisen teknologioihin, vaikka aihetta käsittelevässä kirjallisuudessa ja tutkimuksissa tekoälyteknologioita ei aina erotella vaan esimerkiksi tutkimuksissa, jotka käsittelevät tekoälyn käyttöä budjetoinnissa on käytetty yleiskäsitettä tekoäly. Tutkimuksissa, jotka käsittelevät tekoälyteknologioita ennustusmenetelminä on käytetty erikseen koneoppimisen ja syväoppimisen käsitteitä.

Kirjallisuudessa käsitellään usein rullaavaa budjetointia ja rullaavaa ennustamista synonyymeinä. Bhimani ym. (2018, 308) jaottelee kuitenkin rullaavan ennustamisen olevan keskeisten arvojen ennustamista, joita ei välttämättä liitetä budjettiin, mutta rullaavassa budjetoinnissa nämä ennustetut suunnitelmat liitetään budjettiin. Tutkielmassa tarkastellaan rullaavaa budjetointia nimenomaan budjettia päivittävänä toimenpiteenä ja keskitytään rullaavan budjetoinnin ennustusvaiheeseen, sillä se on olennaisin osa rullaavaa budjetointia, jossa tekoäly voi olla apuna.

Muutamia tieteellisiä tutkimuksia on tehty tekoälyn käytön mahdollisuuksista budjetoinnissa, mutta rullaavaa budjetointia ei ole vielä tutkittu. Tässä tutkielmassa tehdään siis päätelmiä eri artikkeleiden pohjalta ja sovelletaan niitä koneoppimisen ja syväoppimien käyttämiseen rullaavissa ennusteissa. Rhanoui ym. (2019, 320) toteaa, että koneoppimisen ja syväoppimisen käyttämistä budjetoinnissa ja ennustamisessa ei ole tutkittu lähes lainkaan, koska asiaankuuluvia datakokonaisuuksia on vaikea saada ja data on luonteeltaan epävakaata. Tutkielmassa tutkitaan siis tekoälyn mahdollista käyttöä rullaavan budjetoinnin ennusteissa, sillä tutkimuksia ei ole tehty niiden konkreettisesta käyttämisestä. Tutkielma vaatisi enemmän tutkimuksia tekoälyn käyttämisestä, jotta

voitaisiin käsitellä sen käyttämistä konkreettisesti pelkkien oletuksien ja mahdollisuuksien sijasta.

Tutkielma koostuu viidestä pääluvusta. Johdannossa esitellään tutkielman aihe, aiheen rajaukset ja motivaatio tutkielman taustalla. Lisäksi johdannossa esitellään tutkimuskysymykset ja tutkielman rakenne. Toisessa pääluvussa käsitellään tekoälyä käsitteenä ja avataan sen eri luokitteluja. Lisäksi käydään läpi tarkemmin tutkielman kannalta tärkeimmät tekoälyteknologiat koneoppiminen ja syväoppiminen. Kolmannessa pääluvussa käsitellään yritysten budjetointia ja budjetointiprosessia sekä tarkastellaan perinteisen budjetoinnin saamaa kritiikkiä. Lisäksi luvussa käsitellään kritiikin myötä syntyneitä budjetointitapoja, joista päätarkastelun kohteena on rullaava budjetointi. Neljännessä pääluvussa vastataan tutkimuskysymyksiin. Luvussa tarkastellaan tekoälyn käyttöönoton edellytyksiä sekä erikseen koneoppimisen ja syväoppimisen hyötyjä rullaavan budjetoinnin ennusteissa. Lopuksi tutkielmassa on yhteenveto ja johtopäätökset, jossa kerrataan tutkielman tarkoitus ja mitä tutkielmasta opittiin. Lisäksi siinä tuodaan esille tutkielman tärkeimmät päätelmät tekoälyn käytöstä rullaavan budjetoinnin ennusteissa.

2 Johdatus tekoälyyn

Tässä luvussa käsitellään tekoälyn määritelmää, sen luokittelua ja tämän tutkielman kannalta tärkeimpiä tekoälyteknologioita. Ensimmäisessä alaluvussa käsitellään tekoälyn määritelmiä ja mitä haasteita sen määrittelemiseen liittyy. Toisessa alaluvussa tekoälyä luokitellaan kapeaan, yleiseen ja superälyyn sekä analyttiseen, ihmisestä inspiroituneeseen ja ihmistyneeseen tekoälyyn. Kolmannessa alaluvussa tarkastellaan laajemmin koneoppimista ja syväoppimista sekä siihen liittyviä neuroverkkoja tekoälyteknologiana.

2.1 Tekoälyn määritelmä ja sen haasteita

Tekoälylle ei ole yhtä sovittua määritelmää, ja kirjallisuudessa sille on ehdotettu monia määritelmiä. Yksi yleisimpiä määritelmiä on Kaplanin ja Haenleinin (2019a, 15) määritelmä tekoälystä järjestelmän kykyä tulkita ulkoista tietoa oikein, oppia tästä tiedosta ja käyttää oppimaansa tiettyjen tavoitteiden saavuttamiseksi ja tehtävien hoitamiseksi joustavan mukauttamisen avulla. Duan ym. (2019, 63) määrittelee tekoälyn koneen kyvyksi oppia kokemuksesta, sopeutua uusiin syötteisiin ja suorittaa ihmisen suorittamien tehtävien kaltaisia tehtäviä. Kumar ym. (2019, 136) taas määrittelee tekoälyn työkaluna, jolla on loputtomasti valintoja ja informaatiota, jotka voidaan rajata yksilöllisiin tarpeisiin. Euroopan parlamentti (2023) määrittelee tekoälyn koneen kyvyksi osoittaa ihmisen kaltaisia kykyjä, kuten päättelyä, oppimista ja suunnittelua. Tekoälylle annetut määritelmät ovat keskenään eri laajuisia, mutta pääpiirteittäin ne kuitenkin muistuttavat toisiaan.

Tekoälyn määrittelemiseen ja ymmärtämiseen liittyy monia haasteita, ja ymmärrys tekoälyn ja ihmisälyn eroista ja yhtäläisyyksistä on vielä varsin heikkoa (Korteling ym. 2021, 1). Tekoäly ei esimerkiksi ole pelkkä jäljitelmä ihmisen älystä, vaikka karkeasti se voidaankin määritellä sellaiseksi. Suurin havaittava ero ihmisen älyn ja tekoälyn välillä on luovuus. Tekoäly perustuu mallien tunnistamiseen ja on epätodennäköistä, että tekoäly voisi suorittaa mitään oikeasti luovia tehtäviä. (Kaplan & Haenlein 2020, 40.) Tekoälyllä voidaan siis jäljitellä ihmisen älyn teknologista puolta (Cho ym. 2020), mutta se toimii vain matemaattisten laskelmien pohjalta, eikä tekoälyllä ole omaa tietoisuutta (Fülöp ym. 2023, 390).

Haastetta määrittelemiselle tuo myös tekoälyteknologioiden kompleksisuus ja vaikeaselkoisuus. Tekoäly -käsitteen alle lasketaan usein monia sen sovelluksia ja tekniikoita (Jarrah 2018; Bakarich & O'Brien 2021, 28). Monimutkaiset tekoälyteknologiat sisällytetään tekoäly -käsitteen alle, sillä näiden teknologioiden ymmärtäminen ja selittäminen on tullut haastavaksi, ellei jopa mahdottomaksi (Duan ym. 2019, 66).

Lisähaastetta määrittelemiseen tuo lisäksi se, että jo pelkästään ihmisen älyn määrittäminen on haastavaa, joten kun älyyn pitäisi yhdistää vielä koneita, on se entistä haastavampaa. Kun totutaan siihen, että koneet suorittavat monimutkaisia ja vaativia tehtäviä, saatetaan lakata pitämästä niitä älykkäinä, koska tehtävät koetaan tavallisiksi eikä älyllisiksi koneen suorittamiksi tehtäviksi. Tämä vaikeuttaa tekoälyn määrittelyä. (Kaplan & Haenlein 2020, 39.)

2.2 Tekoälyn luokittelua

Tekoälyllä on monia tasoja kapeasta älystä yleiseen älyyn ja vielä superälyyn. (Kaplan & Haenlein 2020, 39). Kapea tekoäly (engl. Artificial Narrow Intelligence) on heikkoa tekoälyä, joka pystyy tiettyyn sille opetettuun tehtävään, mutta ei kykene automaattisesti muihin tehtäviin. Esimerkki kapeasta tekoälystä on Applen puheentunnistusjärjestelmä Siri, joka kykenee tunnistamaan puhetta, mutta ei kykene suorittamaan muita tehtäviä, esimerkiksi ajamaan autoa. Tässä tietyssä tehtävässä se kuitenkin voi olla parempi kuin ihminen. (Kaplan & Haenlein 2019a, 16.)

Yleinen tekoäly (engl. Artificial General Intelligence) taas pystyy automaattisesti ratkaisemaan monia ongelmia ja on ihmistä parempi monilla osa-alueilla. Esimerkiksi yleistä tekoälyä on se, jos Siri muuttuisi ihmisen kaltaiseksi robotiksi, joka kykenisi puheentunnistuksen lisäksi keittämään kahvia ja kirjoittamaan paperille. (Kaplan & Haenlein 2019a, 16.)

Superäly (engl. Artificial Super Intelligence) taas on kaikin puolin ihmistä parempi ja kykenee ratkaisemaan hetkessä kaikenlaiset ongelmat. Yksi esimerkki superälystä olisi, jos Siri omistaisi superihmisen kyvyt ja kykenisi silmänräpäyksessä monimutkaisten matemaattisten ongelmien ratkaisemiseen ja palkitun romaanin kirjoittamiseen. (Kaplan & Haenlein 2019a, 16.) Lähes kaikki tekoälyjärjestelmät ovat kuitenkin kapeaa tekoälyä

(Saha ym. 2021, 2). Nykypäivän tekoäly ei siis kykene tietoiseen ongelmanratkaisuun ja suorittaa yleensä vain yhtä sille määrättyä tehtävää.

Tekoälyä voi luokitella edellä mainitun luokittelun lisäksi analyyttiseen, ihmisestä inspiroituneeseen ja ihmistyneeseen tekoälyyn. Analyyttisellä tekoälyllä (engl. Analytical AI) on vain kognitiivisen älyn ominaisuuksia eli se käyttää aiempiin kokemuksiin perustuvaa oppimista tulevien päätösten tekemiseen. Analyyttinen tekoäly on yleisin yritysten käytössä oleva tekoäly. Se on esimerkiksi järjestelmä, jota käytetään petosten havaitsemiseen tai itseohjautuviin autoihin. Ihmisestä inspiroituneella tekoälyllä (engl. Human-Inspired AI) on piirteitä sekä kognitiivisesta- että tunneälystä. Tällaiset järjestelmät voivat kognitiivisten piirteiden lisäksi ymmärtää ihmisten tunteita ja ottaa ne huomioon päätöksenteossa. Esimerkiksi ihmisestä inspiroitunut tekoälyjärjestelmä voi tunnistaa tunteita samalla tasolla tai jopa paremmin kuin ihmiset. Kaikista kehittynein ihmistynyt tekoäly (engl. Humanized AI) kykenee kognitiiviseen, emotionaaliseen ja sosiaaliseen älykkyyteen. Esimerkiksi ihmistynyt tekoälyjärjestelmä kykenisi olemaan itsetietoinen vuorovaikutuksessa muiden kanssa. Ihmistynyttä tekoälyä ei kuitenkaan ole vielä kehitetty ja jos se joskus kehitetään, se tapahtuu vasta kaukaisessa tulevaisuudessa. (Kaplan & Haenlein, 2019a, 18–19.)

2.3 Tekoälyteknologioita

Tekoälyn menestyksellä käyttöönotto organisaatioissa edellyttää viimeisten vuosien aikana kehittyntä nopeaa ja skaalautuvaa laskentatehoinfrastruktuuria sekä runsasta tietoa-aineistoa. Lisäksi se vaatii algoritmeja, jotka toimivat koneoppimisen tai syväoppimisen ja siinä hyödynnettävien neuroverkkojen avulla. (Wamba-Taguimdje ym. 2020, 1911.) Juuri syväoppiminen ja sen neuroverkot muodostavat perustan useimmille sovelluksille, jotka tunnetaan tekoälynä (Kaplan & Haenlein 2019b, 8). Vaikka tekoälyteknologioita on monia ja niillä on eri käyttötarkoituksia, tutkielmassa keskitytään käsittelemään seuraavissa alaluvuissa tarkemmin koneoppimista ja syväoppimista, sillä näitä teknologioita hyödynnetään tutkielman tutkimuskysymyksiin vastatessa. Koneoppiminen ja syväoppiminen liittyvät toisiinsa, mutta niillä on omat merkityksensä, ja niiden tarkastelu erillään on olennaista (Kufel ym. 2023, 1).

2.3.1 Koneoppiminen

Koneoppiminen (engl. machine learning) on kapeaa tekoälyä ja se määritellään kyvyksi, jolla algoritmi voi oppia ja kehittyä sen kokemusten ja sille syötetyn datan perusteella (Goodfellow ym. 2016, 2–3). Koneoppimisalgoritmien toiminta on siis automatisoitua sellaisten mallien avulla, joita ei ole manuaalisesti ohjelmoitu vaan opetettu datalla (Kufel ym. 2023, 3). Koneoppiminen käyttää algoritmisen mallin rakentamiseksi ensin koulutusdataa, jolla se koulutetaan ja sitten sen toimivuutta testataan erillisellä testidatalla (Cho ym. 2020, 1).

Jotta koneoppimisalgoritmi oppii ja kehittyä itsenäisesti sen kokemusten perusteella, tarvitaan valtava määrä koulutusdataa. Jos uusi algoritmi osoittautuu testausprosessin aikana paremmaksi, koneoppimisalgoritmi hylkää alkuperäisen algoritmin ja alkaa toimia uuden algoritmin tavoin. (Kreutzer & Sirrenberg 2020, 5–6.) Esimerkki yksinkertaisesta koneoppimisjärjestelmästä on algoritmi, joka voi erottaa roskapostiviestit oikeista sähköposteista (Goodfellow ym. 2016, 3).

Kreutzer ja Sirrenberg (2020, 6–7) jakavat koneoppimisen kolmeen oppimisen muotoon, jotka ovat valvottu oppiminen, valvomaton oppiminen ja vahvistava oppiminen. Valvottu oppiminen (engl. supervised learning) on oppimisprosessi, jossa koneoppimisjärjestelmä tietää valmiiksi oikeat vastaukset, ja sen tavoitteena on muokata algoritmit niin, että vastaukset voidaan johtaa mahdollisimman tarkasti olemassa olevasta datakokonaisuudesta. Valvotussa oppimisessä ihminen määrittää algoritmille syötetyn datan ja halutun vastauksen, jolloin algoritmin saavutettua riittävä tarkkuus sitä voidaan soveltaa uusiin tietoihin. (Kreutzer & Sirrenberg 2020, 6–7.) Esimerkiksi valvottua oppimista on se, kun koneoppimisjärjestelmälle annetaan datakokonaisuutena käsinkirjoitettuja merkkejä, ja sen tehtävä on verrata näitä merkkejä tietokoneelta printattuihin vastineisiin ja oppia yhdistämään ne (Kufel ym. 2023, 4).

Valvomattomassa oppimisessä (engl. unsupervised learning) koneoppimisjärjestelmälle ei ole ennalta määrättyä tavoitelopputulosta, vaan sen on tunnistettava itsenäisesti samankaltaisuuksia datasta. Valvomattomassa oppimisessä algoritmi myös vastaanottaa ennalta määrittelemätöntä dataa, josta algoritmin tulisi oppia tunnistamaan erilaisia dataryhmiä, joilla on samanlaiset ominaisuudet. (Kreutzer & Sirrenberg 2020, 6–7.) Valvomaton oppiminen voi olla klusterointia (engl. clustering) eli tietojen ryhmittelyä samankaltaisuuksien ja erojen perusteella, jossa järjestelmä esimerkiksi jakaa eläimet

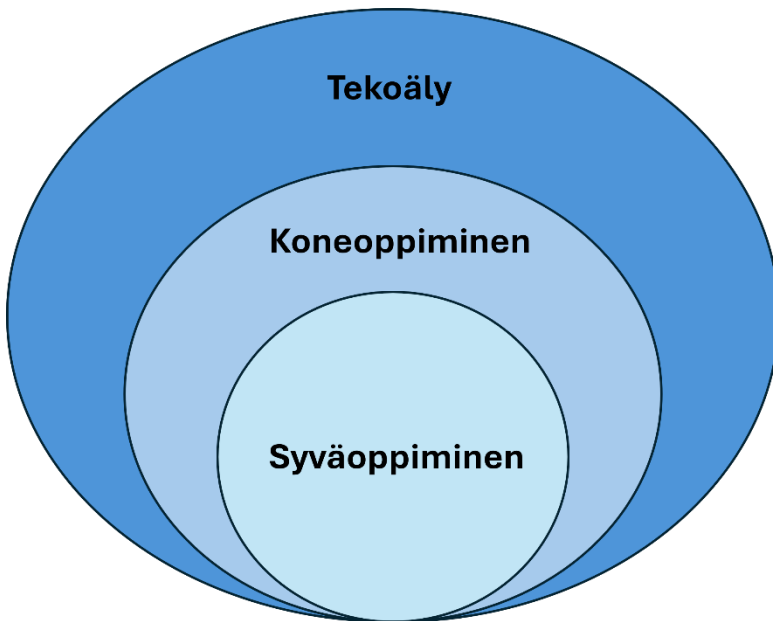
ryhmiin niiden visuaalisten ominaisuuksien perusteella, jotka ovat määritelty mallin avulla. Valvomaton oppiminen voi olla myös assosiaatiota (engl. association) eli datakokonaisuuden tietojen välisien suhteiden analysointia, jossa järjestelmä esimerkiksi yhdistää tiettyä tuotetta ostavat ihmiset sellaisten ihmisten kanssa, jotka ostavat toista tähän tiettyyn tuotteeseen liittyvää tuotetta. (Kufel ym. 2023, 4.)

Vahvistavassa oppimisessa (engl. reinforcement learning) ei ole ennalta määrättyä optimitulosta vaan algoritmi oppii kokeilemalla ja epäonnistumalla. Koneoppimisalgoritmia palkitaan hyvistä ja rangaistaan huonoista ratkaisuista, jolloin se kehittyy. Vahvistavaa oppimista käytetään, kun saatavilla olevaa dataa on vähän, ja haluttu lopputulos on epäselvä. (Kreutzer & Sirrenberg 2020, 6–7.)

Koneoppimisen ansiosta tietokoneet voivat ratkaista ongelmia maailmassa olevan oikean datan perusteella, ja näin ne myös vaikuttavat subjektiivisilta. Se, miten koneoppimisjärjestelmä toimii riippuu täysin siitä, minkälaista dataa ja missä muodossa tämä data sille annetaan. Monet tekoälytehtävät voidaan ratkaista suunnittelemalla oikeat ominaisuudet kyseistä tehtävää varten ja antamalla nämä ominaisuudet koneoppimisalgoritmile. (Goodfellow ym. 2016, 3.) Koneoppimisalgoritmien avulla koneet pystyvät oppimaan saatavilla olevasta datasta ja toimimaan uusissa ympäristöissä usein jopa ilman ihmisen väliintuloa (Wamba-Taguimdje ym. 2020, 1894, 1902).

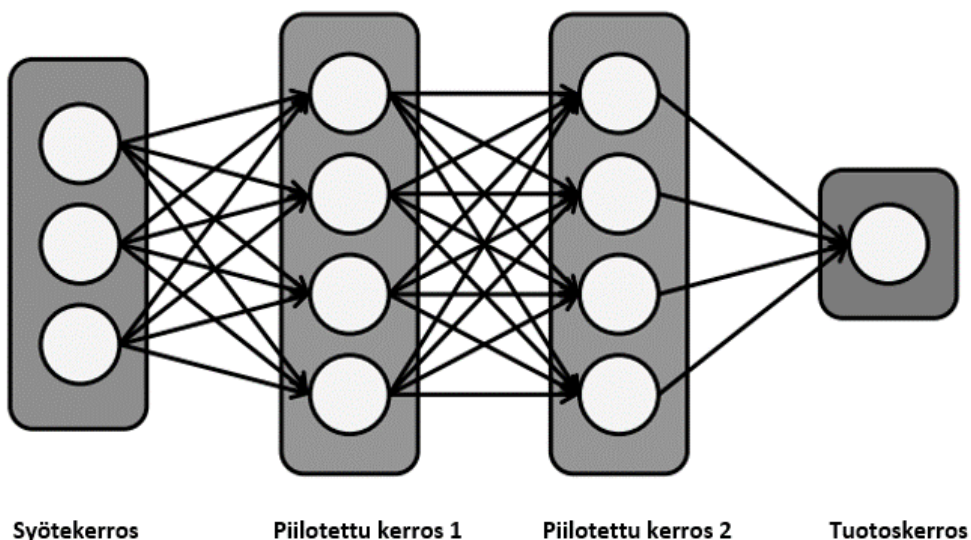
2.3.2 Syväoppiminen

Syväoppiminen (engl. deep learning) on koneoppimisen erikoisteknologia, jota koulutetaan neuroverkkojen (engl. neural networks) avulla. Syväoppiminen toimii muutoin koneoppimisen tavoin, mutta on usein koneoppimista tarkempi sekä monimutkaisempi teknologia. (Goodfellow ym. 2016, 5, 8.) Syväoppimisjärjestelmä kykenee prosessoimaan laajempia dataresursseja, ja se vaatii vähemmän ihmisen suorittamaa tietojen esikäsittelyä (Kreutzer & Sirrenberg 2020, 8). Kuva 1 mallintaa tekoälyä, jonka alle lukeutuu koneoppiminen yhtenä tekoälyteknologiana, ja jonka alle taas lukeutuu syväoppiminen koneoppimisen erikoisteknologia.



Kuva 1 Havainnekuva koneoppimisesta ja syväoppimisestä tekoälyteknologioina (tekijän itse tekemä kuva)

Syväoppimisessä käytettävät neuroverkot ovat saaneet nimensä neurotieteistä, ja ne mukailevat ihmisaivojen neuroneiden toimintaa. Neuroverkot muodostuvat monista kerroksista, joita ovat syötekerros (engl. input layer), piilotetut kerrokset (engl. hidden layer) ja tuotoskerros (engl. output layer). (Kreutzer & Sirrenberg 2020, 4–5.) Neuroverkkojen kerrokset rakentuvat monista toisiinsa sidonnaisista yksinkertaisista solmuista (engl. nodes), jotka käyttäytyvät ihmisaivojen neuroneiden tapaan eli välittävät ja prosessoivat saatua tietoa (Zhang ym. 1998, 37). Yksinkertaisen neuroverkon eri kerroksia mallinnetaan kuvassa 2, jossa jokaisen kerroksen ympyrät kuvaavat neuroverkon solmuja.



Kuva 2 Malli yksinkertaisesta neuroverkosta (Kreutzer & Sirrenberg 2020, 5)

Syötekerros ja sen solmut vastaanottavat sille syötetyn raa'an datan. Piilotetut kerrokset ja sen solmut prosessoivat dataa, jonka saavat edellisen kerroksen prosessoinnin tuloksena. Seuraava kerros ei siis prosessoisi samaa dataa kuin edellinen vaan se prosessoisi edellisen kerroksen antamaa tulosta. Jokaisella kerroksella on oma osaamisalueensa, ja ne toimivat koneoppimisen avulla, jolloin järjestelmän on tarkoitus koko ajan oppia tiedon siirtyessä kerrokselta toiselle. Viimeinen kerros on tuotoskerros, jossa syväoppimisjärjestelmä tuottaa lopullisen tuloksen. (Kreutzer & Sirrenberg 2020, 4–5.)

Sana ”syvä” viittaa syväoppimisalgoritmeille luotujen neuroverkkojen moniin kerroksiin, jotka voivat vastaanottaa suuria määriä dataa (Goodfellow ym. 2016, 5; Kreutzer & Sirrenberg 2020, 8). Kehittyneet syväoppimisalgoritmit käyttävät takaisinkytkettyjä neuroverkkoja (engl. recurrent neural network, RNN) sekä niistä kehittyneitä pitkäkestoisia lyhytkestomuisti -neuroverkkoja (engl. Long short-term memory neural network, LSTM), jotka kykenevät muistamaan tavallista neuroverkkoa paremmin jo käsiteltyä dataa ja ovat siksi olennaisia myös ennustamisessa ja päätöksenteossa. RNN:t ovat erittäin syviä neuroverkkoja, jotka pystyvät käyttämään sisäistä muistia syötteiden käsittelemiseen. Ne voivat jokaisella piilotetulla kerroksella päättää, mitkä tiedot unohdetaan ja mitkä halutaan säilyttää. Niiden ongelmana on kuitenkin, että ne eivät säilytä tietoa pitkään, jolloin niiden on vaikea oppia mitään pitkäaikaisia riippuvuuksia. LSTM-neuroverkot ovat syntyneet RNN:ien rinnalle, koska niiden avulla syväoppimisalgoritmit kykenevät muistamaan tietoja pidempään. LSTM-neuroverkot oppivat ajan kuluessa, mikä tieto on tärkeää, ja mikä voi hylätä. (Rhanoui ym. 2019, 319.)

Syväoppimisalgoritmi osaa jakaa sille syötetyn datan vielä pienempiin osiin tunnistamalla siitä paremmin tiettyjä osia, joissa koneoppimisalgoritmi saattaa mennä pieleen. Syväoppimisjärjestelmät ymmärtävät koneoppimisjärjestelmiä haastavampia ja monimutkaisempia käsitteitä, niiden monitasoisen datankäsittelyprosessin ansiosta. Koneoppimisessa koulutusdatasta tärkeimpien piirteiden valinta tehdään manuaalisesti ja algoritmimalli on yksinkertainen, kun taas syväoppimisessa algoritmit oppivat automaattisesti ja tarkastelevat dataa kerroksittain monimutkaisten neuroverkkojen avulla. (Goodfellow ym. 2016, 6–8.)

Kompleksiset syväoppimisjärjestelmät ja niiden käyttämät monitasoiset neuroverkot ovat yksi pääsyy sille, miksi tekoälystä on tullut käytetty yläkäsite kaikille sen

alateknologioille, koska niiden ymmärtäminen on tullut haastavaksi. Etenkin piilotettujen kerrosten toimintaa neuroverkoissa on vaikea ymmärtää. (Duan ym. 2019, 66.)

Tässä luvussa käytiin läpi tekoälyn määritelmiä, määrittelyn haasteita sekä sen luokittelua niin kapeaan-, yleiseen- ja superälyyn kuin analyttiseen-, ihmisestä inspiroituneeseen- ja ihmistyneeseen tekoälyyn. Lisäksi avattiin tarkemmin, mitkä ovat tutkielman kannalta olennaisimmat tekoälyteknologiat. Syväoppiminen on syntynyt koneoppimisen rinnalle ja luetaan osaksi koneoppimista. Erona näillä kahdella on kuitenkin syväoppimisen monimutkaisempi rakenne, koska syväoppiminen käyttää monitasoisia neuroverkkoja datan prosessointiin, koneoppimisen yksinkertaisempien algoritmien sijasta. Koneoppimista jaotellaan kolmeen oppimisen muotoon, jotka ovat valvottu, valvoton ja vahvistava oppiminen. Näitä hyödynnetään riippuen siitä, mihin tarkoitukseen koneoppimisalgoritmia halutaan käyttää. Kehittynyt syväoppimisalgoritmi käyttää RNN:iä sekä LSTM-neuroverkkoja, koska näillä on kyky säilyttää muistissa jo käsiteltyä dataa, ja etenkin LSTM-neuroverkot pystyvät käsittelemään myös pitkäaikaisia riippuvuuksia datasta, joka on hyödyllistä ennustamisen kannalta.

3 Budjetointi

Tässä luvussa käsitellään perinteistä budjetointia ja sen saamaa kritiikkiä sekä perinteisten budjetoinnin rinnalle syntyneitä budjetointitapoja, joista tarkemmin käsitellään rullaavaa budjetointia. Ensimmäisessä alaluvussa määritellään budjetointi ja budjetti sekä tarkastellaan budjetoinnin tehtäviä. Toisessa alaluvussa käydään läpi, minkälaista kritiikkiä perinteinen budjetointi on saanut ja kolmannessa alaluvussa lyhyesti mitä vaihtoehtoisia tapoja sen tilalle on muodostunut. Viimeisessä alaluvussa keskitytään tarkastelemaan rullaavaa budjetointia, koska se on suosituin budjetointitapa perinteisen budjetoinnin rinnalla.

3.1 Budjetoinnin määritelmä ja sen tehtävät

Perinteinen budjetti on yritykselle ennuste ja suunnitelma seuraavalle vuodelle tai mahdollisesti jopa kahdelle, kolmelle tai viidelle vuodelle. Budjetti rakentuu ennusteiden varaan, joita laaditaan budjetoinnin avulla yleisten olettamien ja kerätyn markkinatiedon pohjalta. (Wallander 1999, 410.) Bhimani ym. (2019, 425) määrittelee budjetin yrityksen talousjohdon määrälliseksi tavaksi ilmaista strategia tietylle tulevaisuuden aikaperiodille, ja se on apuna yrityksen toimintasuunnitelman koordinoimisessa ja implementoinnissa. Neilimo ja Uusi-Rauva (2005, 230–231) taas määrittelevät budjetin rahamittaiseksi toiminnan ohjausvälineeksi, joka luo yksityiskohtaisen kuvan yrityksen toiminnan tavoitteista ja resursseista kyseiselle tarkasteluajanjaksolle sekä yhdistää yrityksen eri toimintoja ja luo niistä yhteisen kokonaisuuden. Budjetti voi kattaa sekä taloudelliset että ei-taloudelliset näkökulmat (Bhimani ym. 2019, 425). Budjettia voidaan kutsua myös talousarvioksi tai tavoitelaskelmaksi riippuen organisaatiosta (Ikäheimo ym. 2019, 154).

Budjetointi tarkoittaa yleisesti organisaatioissa budjetin laatimista. Budjetointi voi olla esimerkiksi ennustamista, suunnittelua, koordinointia, tarkkailua ja valvontaa, motivointia ja suorituksen arviointia varten tai sitten se voi toimia lupana käyttää johonkin rahaa. (Ikäheimo ym. 2019, 155–156.) Budjetoinnissa otetaan huomioon muun muassa kysyntä, kustannukset, hinnat, vaihtokurssit sekä palkat (Wallander 1999, 410).

Budjetointiprosessi koostuu pääpiirteittäin budjetin suunnittelusta eli ennusteiden ja suunnitelmien tekemisestä, toteutuksesta eli itse budjettien konkreettisesta laatimisesta ja tarkkailusta eli budjetissa pysyvyyden seuraamisesta. On tärkeää, että budjetoinnin suunnitteluvaiheessa otetaan huomioon yrityksen menneisyyden kehitys ja sitä arvioidaan

suunniteltavien budjettitavoitteiden kannalta. Lisäksi suunnitteluvaiheessa päätetään seuraavan budjettikauden tavoitteista ja hahmotellaan toimintaympäristön mahdollisia muutoksia, joita tulee budjetissa ottaa huomioon. Yrityksen budjettisuunnitelman ollessa valmis budjetit laaditaan ja niitä ryhdytään noudattamaan päätettynä ajankohtana. Lisäksi täytyy vielä kohdistaa yhteiset budjettitavoitteet niille kuuluville osastoille, esimerkiksi myyntibudjetin tiedot myyntipäällikölle. (Neilimo & Uusi-Rauva 2005, 234.) Budjetteja tarkkaillaan varianssianalyysin avulla. Varianssianalyysin avulla vertaillaan budjetoitua tavoitelukua toteutuneeseen lukuun. Saadun varianssin pohjalta tehdään johtopäätöksiä toiminnassa onnistumisesta ja tehdään selvityksiä mahdollisista poikkeamista. (Åkerberg 2017, 37–38.)

Budjetoinnilla nähdään olevan yrityksille monia hyötyjä. Budjetti on vuositasolla talousjohton tärkeimpiä ohjauksen välineitä (Neilimo & Uusi-Rauva 2005, 230), ja se on yksi maailmanlaajuisesti käytetyin menetelmä kontrolloida ja suunnitella yritysten toimintaa. Sen avulla talousjohto voi seurata vuositasolla yrityksen resursseja ja toiminnan kehitystä sekä suunnitella tulevaisuutta. (Bhimani ym. 2019, 424.) Perinteinen vuositasoinen budjetti on usein sidoksissa myös johdon palkitsemisjärjestelmään, joka lisää motivaatiota budjettitavoitteiden saavuttamiseen. Perinteiset budjetit siis motivoivat yrityksiä suunnittelemaan taloudellista toimintaansa ainakin kerran vuodessa. (Ikäheimo ym. 2019, 155–156.) Perinteinen budjetti määrittää johtamisen vastuualueet ja voi toimia organisaation selkeyttäjänä sekä pitkän aikavälin tavoitteiden täsmentäjänä (Neilimo & Uusi-Rauva, 2005, 235).

3.2 Perinteisen budjetoinnin kritiikki

Vaikka perinteisellä budjetoinnilla on myös etuja, sen toimivuutta on kyseenalaistettu, ja siihen kohdistuvaa kritiikkiä on esitetty laajasti. Perinteinen budjetointi on kehitetty täysin erilaiseen ympäristöön nykypäivän maailmaan verrattuna, sillä sen kehittämisen aikaan kysyntää oli aina enemmän kuin tarjontaa, ja kilpailijoiden toimia oli kohtalaisen helppo ennakoida. Nykypäivän toimintaympäristö on usein nopeiden muutosten alla esimerkiksi kansainvälisten kriisien tai energian ja raaka-aineiden hintamuutosten vallitessa. (Åkerberg 2017, 37, 50.)

Perinteinen budjetointi on hyvin aikaavievää, ja se on jo valmistuessaan osittain vanhentunut. Perinteisen budjetoinnin suunnitteluprosessi vie resursseja ja tuhansia työtunteja koko organisaatiolta. (Ikäheimo ym. 2019, 162.) Nykypäivänä useimmissa

yrityksissä budjetointisuunnittelussa ennustusten tekeminen on tärkein osa budjetointiprosessia. Ennusteet tehdään epävarmuuden vallitessa, ja jotta tavoiteltavat luvut saavutettaisiin, saatetaan ne laatia tarkoituksellisesti matalammiksi. Sen lisäksi, että ennusteiden tekeminen on pitkälle aikavälille aikaavievää se on myös vaikeaa. Ennusteet ovatkin usein vanhentuneita heti niiden voimaantullessa, sillä markkinatilanne voi muuttua nykypäivänä äkillisesti. Tällöin ennusteet eivät ole budjettikaudella enää ajankohtaisia ja luotettavia. (Åkerberg 2017, 39–40.)

Budjettien tulisi olla linkitetty yrityksen strategiaan, jolloin ne voisivat ohjata yritystä strategian mukaisiin tavoitteisiin. Tämä harvoin kuitenkaan perinteisen budjetoinnin kohdalla toteutuu, sillä budjettien suurena ongelmana on se, että pyritään seuraamaan vain asetettuja lukuja, eikä oteta huomioon liiketoimintastrategiaa ja arvonluomista. (Neely ym. 2003, 23.) Budjetoinnissa otetaan siis strategisten tavoitteiden tai ulkoisten muutosten sijasta huomioon usein vain edellisten vuosien budjetit, joiden pohjalta ennusteita muodostetaan (Ikäheimo ym. 2019, 162).

Perinteinen budjetointi on lisäksi usein innovaatioiden ja kilpailuedun saavuttamisen tiellä, sillä budjetointi on usein hyvin kontrolloitua ja täten estää luovan innovoinnin ja oppimisen (Frow ym. 2010, 445). Kun budjetointia kontrolloidaan vahvasti, eikä kerran määrättyistä luvuista jousteta, on mahdollisuus, että yrityksen liiketoiminta kärsii menetetyistä mahdollisuuksista, joita budjetointirajoitteet aiheuttavat. Åkerbergin (2017, 99) mukaan perinteisellä budjetoinnilla on ”sementtoiva” vaikutus, eli kun se kerran pitkässä prosessissa on laadittu, ei sitä helposti lähdetä enää muokkaamaan. Jo budjetoiduista luvuista muodostuu usein siis raamit sille, minkälaista tuottoa tavoitellaan ja minkälaiset kustannukset ovat hyväksyttäviä (Åkerberg 2017, 47). Esimerkiksi tällainen tilanne voi olla, kun kesken budjettivuoden halutaan tehdä mielekäs investointi, jota ei ole tajuttu sisällyttää budjettiin. Tällöin investointi jää mahdollisesti tekemättä, koska budjettia ei voida lähteä muuttamaan tai ylittämään. (Ikäheimo ym. 2019, 162.)


Perinteinen budjetointi voi altistaa myös sisäiselle pelaamiselle, sillä usein organisaatioissa ajatellaan, että budjettivuoden loppupuolella tehdään huomatuista budjettirajoitteista johtuen kiristyksiä. Käytännössä tämä tarkoittaa sitä, että eri osastot mahdollisesti pyrkivät saamaan budjettiinsa enemmän rahaa kuin oikeasti tarvitsisivat vuoden ajaksi, jotta tuotantoa olisi mahdollista jatkaa entiseen malliin huolimatta budjettivuoden lopun kiristyksistä. Toisaalta pelaaminen voi näkyä myös koko

budjettivarojen käyttämisenä siinä toivossa, että seuraavana vuonna budjettiin saadaan taas sama määrä rahaa, eikä leikattaisi tietyn osaston rahoista. Tällainen pelaaminen muodostaa vääristymiä budjettiin. (Ikäheimo ym. 2019, 162.)

Monet kriitikot ovat väittäneet, että perinteinen budjetointi täytyy korvata jollain joustavammalla budjetointitavalla. Perinteinen budjetointi ei toimi tilanteissa, joissa on suurta epävarmuutta esimerkiksi muuttuvan teknologian, globaalien markkinoiden, valtion sääntelyn, kilpailun tai uuden tiedon lisääntymisen takia. (Ekholm & Wallin 2011, 145.) Neely ym. (2003, 22) mukaan budjettiuudistus on monien tutkimusten mukaan rahoitusjohtajien pääprioriteettina, sillä jopa 80 prosenttia yrityksistä ovat tyytymättömiä suunnittelu- ja budjetointiprosesseihinsa.

3.3 Vaihtoehtoisia budjetointitapoja

Kuvassa 3 on kuvattu erilaisia budjetointitapoja verrattuna kiinteään vuosibudjettiin, joita on syntynyt perinteisen budjetoinnin rinnalle tarjoamaan ratkaisuja sen kohtaamaan kritiikkiin ja ratkaisemaan nykypäivänä siihen liittyviä ongelmia.



Kuva 3 Erilaisia budjetointitapoja (Pellinen 2017, 69)

Kuvassa 3 Pellinen (2017, 73) jakaa erilaiset budjetit kiinteään perinteiseen vuosibudjettiin, joustavaan budjettiin ja rullaavaan budjettiin. Kiinteän vuosibudjetin ja joustavan budjetin palkit kuvaavat yhtä vuotta. Kiinteä vuosibudjetti on ajallisesti siis vuoden mittainen, ja se valmistellaan edeltävänä vuonna syksyn aikana, jonka jälkeen sitä seurataan vuoden ja valmistellaan sitten seuraavalle vuodelle uusi budjetti. Joustavassa budjetoinnissa yritys tekee useampia vaihtoehtoisia budjetteja, jotka

eroavat toisistaan eri muuttujien suhteen. Ne tehdään kuitenkin samalle määrätulle aikaperiodille esimerkiksi vuodelle kuten kuvassa 3 on havainnollistettu. Rullaava budjetointi taas ovat erinomainen budjetointitapa epävarmalle toimintaympäristölle, jossa on nopeita muutoksia, sillä suunnitelmat tarkentuvat tietyin väliajoin, ja budjetointia tehdään jatkuvasti. Rullaavat budjetit eivät siis kuvan palkin mukaisesti sijoitu vuodelle vaan aina edellisen aikaperiodin loppuessa tehdään uusia ennusteita sovittun ajan päähän. (Pellinen 2017, 73.) Rullaava budjetti on näistä esitetyistä tavoista ainoa, joka ei asetu ajallisesti tietyn mittaiseksi vaan sitä luodaan jatkuvasti, jolloin se on myös joustavampi ja sopii paremmin muuttuviin ympäristöihin.

3.4 Rullaava budjetointi

Rullaava budjetti on suunnitelma, joka on aina avoinna tietylle tulevaisuuden aikaperiodille ja jonka perään lisätään aina uusi kuukausi, vuosineljännes tai vuosi, kun juuri meneillään ollut kuukausi, vuosineljännes tai vuosi päättyy (Bhimani ym. 2019, 430). Tulevaisuuden aikaperiodi, jonka ajalle ennusteet tehdään, pysyy siis vakiona, sillä päivitys budjettiin tehdään aina, kun edellinen aikaperiodi päättyy (Bhimani ym. 2018, 308). Neilimon ja Uusi-Rauvan (2005, 243) esimerkissä rullaavassa budjetoinnissa yrityksen budjettikausi pidetään aina saman mittaisena, esimerkiksi kun vuoden tarkastelujakson ensimmäinen vuosineljännes 1.1.–31.3. on kulunut, lisätään vuoden tarkastelujakson loppuun heti uusi vuosineljännes alkamaan 31.12 jälkeen. Tässä esimerkissä budjetointia tehdään siis neljä kertaa vuodessa tekemällä aina uusi neljännesvuosibudjetti alkamaan seuraavan kolmen neljännesvuoden jälkeen, jolloin tarkastelujakso pysyy kokoajan vuoden mittaisena.

Rullaavaan budjetointiin siirtyessä halutaan usein ennakoida paremmin vuositulosta, parantaa reagoitokykyä, siirtyä kalenterivuoteen sidotusta suunnittelusta jatkuviin suunnitelmiin, parantaa kassavirtojen hallintaa tai vähentää turhaa vanhentuvista ennusteista johtuvaa työtä. Ennusteiden säännöllisellä päivittämisellä tavoitellaan ensisijaisesti kykyä reagoida paremmin asiakassuhteiden, kassavirtojen, kilpailukyvyn tai muiden tekijöiden turvaamiseksi. Rullaavalla budjetoinnilla ei pyritä ainoastaan ennustamaan tarkemmin tulevaisuutta vaan myös herättämään tarvittaviin toimenpiteisiin, joita ilmenneet muutokset edellyttävät. (Åkerberg 2017, 104.)

Ennustaminen kuuluu läheisesti rullaavaan budjetointiin, ja ennusteet ovat usein pääsyy sille, miksi budjetointia ryhdytään tekemään useammin kuin perinteisesti kerran vuodessa

(Åkerberg 2017, 103). Åkerberg (2017, 98–99) jakaa ennusteet kolmeen kategoriaan: lähitulevaisuuden, liiketoiminnan kehityksen ja pitkän aikavälin strategian ennustaminen. Lähitulevaisuuden ennusteiden avulla ei ehditä tekemään merkittäviä muutoksia yrityksen kehityksen muuttamiseksi, minkä takia tärkeintä olisi keskittyä liiketoiminnan kehityksen ennustamiseen. Liiketoiminnan kehityksen ennustaminen on otollisin ennustusmuoto rullaavassa budjetoinnissa, sillä sen aikahorisontti on pidempi, ja sen avulla resursseja allokoimalla voidaan saavuttaa asetetut strategiset tavoitteet. (Åkerberg 2017, 98–99.) Rullaava budjetointi korjaa perinteisen budjetoinnin ennusteiden vanhenemisongelman, koska budjettia päivitetään aina tarpeen tullen jokaisella budjetointikerralla verrattuna kerran vuodessa tehtävään perinteiseen budjetointiin.

Perinteisen budjetoinnin saaman kritiikin myötä monet asiantuntijat väittävät, että se tulisi korvata rullaavilla budjeteilla ja ennusteilla niiden joustavuuden takia (Ekholm & Wallin 2011, 145). Rullaava budjetointi ratkaisee vuosittain tapahtuvan perinteisen budjetin monet ongelmat ja siten johtaa myös tarkempiin ennusteisiin. Se reagoi paremmin muuttuviin olosuhteisiin, mutta vaatii pysyviä resursseja hallinnointiin. (Neely ym. 2003.) Rullaava budjetointi sopii lisäksi pörssinoteerattujen yritysten käyttöön myös siitä syystä, että pörssinoteerattujen yritysten tulee antaa tulosvaroitusta mahdollisista odottamattomista muutoksista, jotka huomataan tekemällä rullaavaa budjetointia (Ikäheimo ym. 2019, 161).

Rullaava budjetointi luo mahdollisuuden korjata virheet esimerkiksi valmistusprosessissa, koska useammin tehty budjetointi mahdollistaa virheiden huomaamisen nopeammin. Esimerkiksi jos uuden tuotteen julkaisussa ilmenee ongelmia ja menekki ei vastaakaan odotettua, voidaan rullaavan budjetoinnin avulla muuttaa suunnitelmia, tehdä uusia investointeja ja allokoida resursseja uudestaan strategisten tavoitteiden saavuttamiseksi. (Frow ym. 2010, 445.) Rullaava budjetointi linkittyy tällöin paremmin strategiaan kuin perinteinen budjetointi, ja se kannustaa innovaatioihin ja uusiin investointeihin, sillä budjetoidut luvut ovat joustavampia, kun niitä päivitetään useita kertoja vuodessa. Budjettien säännöllinen päivittäminen voi vähentää myös halua sisäiselle pelaamiselle, koska rullaava budjetointi ratkaisee perinteisen budjetoinnin loppuvuoden ongelman (Neely ym. 2003, 24), jolloin kiristyksiä yleensä budjetteihin tehdään huomattujen budjettirajoitusten takia.

Rullaava budjetointi on laajalti käytetty, mutta monet yritykset käyttävät sitä perinteisen budjetoinnin rinnalla eikä sen sijasta (Bhimani ym. 2018, 319). Frow ym. (2010, 459) painottavat, ettei perinteisen budjetoinnin hylkääminen kokonaan välttämättä ole paras vaihtoehto. Ikäheimo ym. (2019, 161) toteavat rullaavan budjetoinnin sopivan erityisesti muuttuvien kustannusten ja myynnin ennustamiseen, mutta kiinteiden kustannusten ennustamista voidaan tehdä harvemmin, kuten kerran kuudessa kuukaudessa tai vuositasolla. Kihnin (2023) tutkimuksessa erilaisten budjettityyppien käytöstä organisaatioissa todetaan, että budjettityyppien kokeilu johti perinteisen budjetoinnin jatkumiseen sekä rullaavan budjetoinnin implementointiin, koska perinteistä budjetointia pidetään vielä tärkeänä esimerkiksi resurssien suunnittelun ja pitkäaikaisten tavoitteiden asettamisen kannalta.

Perinteinen budjetointi määrittää organisaation tavoitteen, kun rullaava budjetointi taas antaa realistisen ja tarkan kuvan tulevaisuudesta (Ikäheimo ym. 2019, 161). Ikäheimo ym. (2019, 162) painottavat, että jos yritys luopuu perinteisestä budjetoinnista kokonaan, se käyttää usein jotain muuta mekanismia tavoitteiden asettamiseen ja suorituksen arviointiin rullaavan budjetoinnin rinnalla. Vaikka rullaava budjetointi on joustavaa, johtajien kannalta se on usein vaikeasti ymmärrettävissä nopeiden muutosten takia. Se saattaa siis tuoda mukanaan myös epävarmuutta organisaation johdolle. (Asogwa & Etim 2017, 117.)

Tässä luvussa käytiin läpi budjetointia, perinteisen budjetoinnin kritiikkiä ja siitä syntyneitä uudempia budjetointitapoja, tarkemmin rullaavaa budjetointia. Perinteinen budjetointi on toimintaa, jossa laaditaan budjetti monivaiheisen budjetointiprosessin avulla tietylle ajanjaksolle, yleensä vuodelle. Sen saaman kritiikin myötä etenkin rullaava budjetointi on yleistynyt. Rullaava budjetointi on todettu toimivaksi monissa organisaatioissa, ja se ratkaisee perinteisen budjetoinnin kohtaamia ongelmia sen joustavuuden ja säännöllisesti päivitettyjen budjettien ansiosta. Etenkin ennustaminen ja ennusteiden laatiminen on syynä rullaavaan budjetointiin siirtymiselle. Perinteistä budjetointia käytetään usein kuitenkin vielä rullaavan budjetoinnin rinnalla, sillä perinteinen budjetointi toimii paremmin pitkän aikavälin tavoitteiden asettajana, kun rullaavaa budjetointia käytetään tarkan kuvan antamiseen lähitulevaisuudesta.

4 Tekoälyn käyttö rullaavan budjetoinnin ennusteissa

Tässä luvussa käsitellään tekoälyn sekä tarkemmin rajaten koneoppimisen ja syväoppimisen mahdollisuuksia rullaavan budjetoinnin ennusteissa. Lisäksi luvussa avataan tekoälyn käyttöönoton mahdollistavia tekijöitä ja toisaalta sitä, mitä pitää ottaa huomioon tekoälyn onnistuneessa käyttöönotossa organisaatioissa. Ensimmäisessä alaluvussa tarkastellaan, mikä on mahdollistanut tekoälyn käyttöönoton ja mitä tulee ottaa huomioon, kun tekoälyä aletaan hyödyntämään. Toisessa alaluvussa keskitytään tarkastelemaan ennustamista rullaavassa budjetoinnissa ja tutkitaan tarkemmin koneoppimisen ja syväoppimisen vahvuuksia rullaavan budjetoinnin ennusteissa sekä vertaillaan niitä ennustusmenetelminä.

4.1 Tekoälyn käyttöönoton edellytyksiä

Viimevuosina tietotekniikkaa (IT) on käytetty laajalti yrityksissä. Tietotekniikkaosaamista on kehitetty, koska se auttaa yrityksiä ratkaisemaan resurssirajoitteista johtuvien pullonkaulojen haasteita sekä helpottaa erilaisten resurssien tehokasta kohdentamista ja hyödyntämistä organisaatioissa sekä niiden ulkopuolella kilpailuetujen luomiseksi. (Wang 2022, 609.) Tekoäly on nykypäivänä tietotekniikkakentän johtavia teknologioita, ja sen ymmärtäminen ja hyödyntäminen auttaa ratkaisemaan monia organisaatioiden kohtaamia ongelmia.

Tekoälyn kehityksen on mahdollistanut big datan lisääntyminen, joka mahdollistaa tekoälyn tarkemman koulutuksen ja käyttämisen. Big datalle on myös tekoälyn tavoin monia määritelmiä. Euroopan komissio (2022) määrittelee big datan suuriksi määriksi dataa, joka on tuotettu nopeasti useista eri lähteistä, ja se voi olla joko ihmisten tai koneiden tuottamaa. Tekoälyn avulla big data voidaan kerätä ja luokitella tehokkaammin. Tämä tarkoittaa sitä, että suuria tietomääriä voidaan käsitellä paljon lyhyemmässä ajassa ja sitten arvioida ja jäsentää uudelleen tarvittavien vastausten etsimistä varten. Tämä säästää aikaa ja resursseja sekä tarjoaa nopeampia ratkaisuja erilaisiin päätöksiin. (Bakarich & O'Brien 2021.) Tekoälyn mahdollisuudet ovat siis kasvaneet big datan myötä. Myös koneoppiminen ja etenkin sen erikoisteknologia syväoppiminen hyödyntävät toiminnassaan big dataa.

Tekoälyn kehitys on ollut nopeaa viimeisten vuosikymmenten aikana, mutta sen jatkuvan nopean kehityksen uskotaan tulevan päätökseen tai hidastuvan merkittävästi

tietoteknisten fyysisten rajoitteiden takia. Tämä tarkoittaa sitä, että nykypäivän tietokoneiden laskentateho ei voi enää kehittyä samaa tahtia. Tekoälyn kehitys riippuu saatavilla olevan tiedon lisääntymisestä, joten luultavasti tekoälyn kehityskin hidastuu tulevaisuudessa, kun tietokoneet eivät voi prosessoida tiettyä määrää enempää tietoa. Tekoälyjärjestelmien suorituskyky voi kasvaa, mutta ne eivät voi ikinä tuottaa enemmän tietoa kuin mitä niille on syötetty. (Kaplan & Haenlein 2020, 40.) Voidaan todeta, että tämän takia myöskään aikaisemmin tarkasteltujen superälyn tai ihmistyneen älyn saavuttaminen ei ole todennäköistä ainakaan lähitulevaisuudessa.

Tekoälyjärjestelmien avulla organisaatioissa voidaan saada markkinoilla olevista hajanaisista datamassoista poimittua systemaattisesti kaikista tärkeimmät asiat sekä hyödynnettyä kerätty data liiketoimintapäätöksissä. Tämä helpottaa päätöksentekoprosessia monilla liiketoiminnan osa-alueilla, koska tekoälyjärjestelmän avulla voidaan kerätä ainoastaan päätöksenteon kannalta hyödyllinen tieto, jolloin säästyy myös aikaa ja vaivaa. (Sestino & De Mauro 2022.) Tekoäly helpottaa päätöksentekoprosessia liiketoiminnassa siis myös esimerkiksi rullaavassa budjetoinnissa sen ennusteita tehdessä. Koneoppiminen ja syväoppiminen ovat keskeisessä roolissa tekoälyä hyödyntävän päätöksenteon taustalla.

Tekoälyn käytöstä liiketoiminnassa on tehty monia tutkimuksia. Chenin ym. (2023) Kiinassa toteutetussa kyselytutkimuksessa tutkittiin johtajien käsityksiä tekoälyn käytöstä liiketoiminnassa tehokkaiden toimintojen toteuttamiseksi COVID-19 pandemian aikana. Tutkimuksen tulokset osoittavat, että tekoälyn käytöllä toimitusketjujen hallinnassa, varastonhallinnassa, liiketoimintamalleissa ja budjetoinnissa on merkittävän positiivinen yhteys johtajien tyytyväisyyteen. Tekoälyn rooli on todettu tärkeäksi monella liiketoiminnan osa-alueella ja varsinkin epävarmojen olosuhteiden vallitessa tekoälyn käyttö on välttämätöntä kilpailukyvyyn säilyttämisen kannalta. (Chen ym. 2023.)

Taulukossa 1 on esitetty, mitä on otettava huomioon organisaatiossa, jotta tekoäly voidaan implementoida tehokkaasti ja onnistuneesti.

| | Sisäinen | Ulkoinen |
|-----------|---|--|
| Luottamus | Johtajien on osoitettava luottamusta työntekijöitään kohtaan nopeasti muuttuvassa työympäristössä | Kuluttajien on luotettava organisaation tekoälyjärjestelmien kykyihin ja suosituksiin |
| Muutos | Työntekijöiden on jatkuvasti mukauduttava muuttuviin tehtäviin ja kehittää taitojaan jatkuvalla oppimisella | Kilpailijoita on tarkkailtava sekä on pystyttävä kilpailemaan paremman laitteiston ja tiedon avulla |
| Kontrolli | Koneita on ohjattava autonomisten päätösten ja koneiden vinoutumien välttämiseksi | Valtioiden on valvottava johtajien, työntekijöiden, koneiden, kuluttajien ja kilpailijoiden ekosysteemiä |

Taulukko 1 Raamit tekoälyn onnistuneeseen implementointiin organisaatioissa (Kaplan & Haenlein 2019a, 20)

Taulukon 1 mukaan tekoälyn tehokas käyttö liiketoiminnassa lähtee sekä organisaation sisältä että myös ulkoa. Tarvitaan sekä johdon, työntekijöiden että asiakkaiden panos tukemaan tekoälysiirtymää. Luottamus ja jatkuvan oppimisen tärkeys korostuu, sillä tekoäly-ympäristö on nopeasti muuttuvaa ja sen käyttämiseen täytyy löytyä luottamusta ja osaamista. Lisäksi taulukosta 1 nähdään, että tekoälyn käyttö vaatii myös sen kontrollointia niin organisaation sisällä kuin myös valtion tasolla. Tästä voidaan päätellä, että tekoälyn käyttöönotto liiketoiminnassa vaatii monia muutoksia ja prosessiin liittyy monia huomioonotettavia asioita. Tekoälyteknologian käyttö liiketoiminnassa mahdollistaa kuitenkin tehokkaammat prosessit, ja tekoälyn avulla voidaan parantaa monia liiketoiminnan osa-alueita kuten taloushallinnon tuottamaa rullaavaa budjetointia.

4.2 Tekoälyn mahdollisuudet rullaavan budjetoinnin ennusteissa

Yrityksen markkinakysyntää ei voida tietää etukäteen ja siksi tuotteiden tulevaisuuden kysyntä rakentuu pääasiassa yrityksen myyntitietoihin datan ennustusmenetelmiä käyttämällä. Ennustusvalmiudet ovat tulleet yritykselle erityisen tärkeäksi päätöksenteon tueksi epävarmojen ympäristöjen yleistyttyä. Yrityksille on erityisen tärkeää pystyä vastaamaan markkinoiden kysynnän muutoksiin, sillä se vaikuttaa muun muassa yrityksen varastohallintaan, tuotanto- ja myyntiriskeihin sekä parantaa asiakaspalvelua ja kilpailukykyä. (Wang ym. 2021, 2.)

Wangin (2022) toteuttamassa kyselytutkimuksessa tarkastellaan tekoälyä hyödyntävän tietotekniikan ja budjetoinnin sekä organisaation suorituskyvyn välistä suhdetta huipputeknologiayrityksissä (engl. high-tech enterprise). Tutkimuksessa todettiin, että tietotekniset peruskyvykkyudet ja valmiudet vaikuttavat myönteisesti budjetoinnin tehokkuuteen ja tarkkuuteen. Lisäksi todettiin, että tekoälyllä tehostetut budjettikäytännöt voivat parantaa merkittävästi organisaation suorituskykyä. Tutkimuksessa korostetaan tekoälyn merkitystä budjetoitiprosessissa parempien organisaatiotulosten saavuttamiseksi. Mitä korkeammalla tasolla tekoälyä käytetään budjetoinnissa, sitä tarkempi ja tehokkaampi budjetoitiprosessi on (Wang 2022, 616).

Tekoäly on todettu hyödylliseksi välineeksi budjetoinnissa ja etenkin ennustamisen tärkeys korostuu epävarmoissa ympäristöissä. Ennustusmenetelmiä on tutkittu paljon, ja niitä on sekä laskennallisia että laadullisia menetelmiä, mistä uusimpina ja potentiaalisimpina ovat datamäärien kasvaessa syntyneet tekoälypohjaiset menetelmät (Wang ym. 2021, 3). Åkerberg (2017, 102) korostaa, että esimerkiksi sääennusteet ovat tarkentuneet huomattavasti tehokkaan teknologian käyttöönoton myötä, jonka takia myös rullaavan budjetoinnin ennusteissa täytyy hyödyntää teknologiaa.

Rullaavaan budjetointiin liittyy merkittävästi toistettavat prosessit, koska uusia ennusteita tehdään jatkuvasti edellisen kuukauden tai neljännesvuoden päättyessä. Tekoäly on lähes välttämätön apukeino toistettavissa prosesseissa, koska se kykenee tekemään ne tarkemmin ja nopeammin kuin ihminen (Cho ym. 2020, 1). Rullaavaa budjetoitintia rakennetaan jatkuvasti, joten on tärkeää, että käytettävissä on paljon dataa, jonka perusteella jatkuvasti uusia ennusteita voidaan tehdä ja niistä voidaan hyötyä. Tietokoneiden laskentatehon ja big datan kasvun myötä datan käsittelykustannukset ovat laskeneet, ja sen läpikäyminen on nopeampaa, jolloin tekoälyn avulla suuria määriä dataa voidaan reaaliaikaisesti luokitella, järjestellä ja prosessoida (Cho ym. 2020, 1–3.) Kerätystä datasta voidaan tekoälyn avulla tehdä päätöksiä ja vertailla niitä yrityksen omiin kirjanpitolukuihin. (Wang 2022.) Tekoälyn mahdollisuudet rullaavan budjetoinnin ennusteissa voidaan siis jakaa datan järjestelemiseen ja ennustuspäätöksentekoon.

Data voidaan jakaa jäseneltyyn (engl. structured) ja jäsentämättömään (engl. unstructured). Jäsenelty data on järjestelmällisessä muodossa, kun taas jäsentämätön data on epäjärjestelmällisessä muodossa, jolloin sen analysointi on vaikeampaa. (Malviya & Malmgren 2018, 17–21.) Jäseneltyä dataa on esimerkiksi yrityksen sisäiset

datakokonaisuudet kuten kirjanpitoliedot (Ranta ym. 2023, 622). Jäsentämätöntä dataa taas on suurin osa big datasta eli esimerkiksi kirjat, äänitiedostot, videot, kuvat, sosiaalisen median julkaisut ja nettisivut (Malviya & Malmgren 2018, 21).

Koska koneoppiminen ja syväoppiminen liittyvät läheisesti toisiinsa, jaetaan tutkielmassa koneoppimisen ja syväoppimisen käyttömahdollisuudet rullaavan budjetoinnin ennusteissa sen perusteella, kuinka laajasti yritys haluaa käyttää tekoälyä ja kuinka paljon dataa yrityksellä on käytettävänä.

4.2.1 Koneoppiminen

Jos yrityksen tavoitteena on hyödyntää tekoälyä rullaavan budjetoinnin ennusteissa, mutta säilyttää silti taloushallinnon ihmisten asema vahvana, koneoppimisen hyödyntäminen on mielekästä, sillä se toimii hyvin jäsenneilyn datan järjestelijänä. Koska koneoppimisalgoritmia koulutetaan tietyllä määrättyllä datalla (Cho ym. 2020, 1, 4), ja valvomattomassa oppimisessa se kykenee löytämään yhteyksiä tietystä sille annetusta datasta (Kreutzer & Sirrenberg 2020, 6–7), koneoppimisalgoritmi sopii etenkin sellaisten yritysten rullaavan budjetoinnin ennustamiseen, jotka haluavat käyttää vain tiettyä määrättyä dataa rullaavan budjetoinnin ennusteissa.

Koska budjetointi on saanut kritiikkiä siitä, että ennusteet perustuvat usein vain edeltäviin budjetteihin (Ikäheimo ym. 2019, 162), rullaavassa budjetoinnissa on tärkeää, etteivät ennusteet perustu ainoastaan niihin, vaan huomioidaan myös muu mahdollinen yrityksen sisäinen sekä markkinoilta saatava data. Olennaisin data rullaavan budjetoinnin ennustamisessa tulee kuitenkin yrityksen sisältä, ja yrityksen sisäiset datakokonaisuudet ovat laskentatoimen kentällä usein selkeästi jäsenneiltyjä. Koneoppimisalgoritmi kykenee käsittelemään dataa, joka on esimerkiksi yrityksen sisäisiä tekstimuotoisia dokumentteja tai laskettavassa muodossa olevaa dataa, kuten liikevaihtotilastoja. Koneoppimisalgoritmit ovat etenkin tällaisen datan käsittelyssä parempia kuin syväoppimisessa käytettävät neuroverkot. (Ranta ym. 2023, 622).

Koneoppiminen nopeuttaa datan läpikäymistä ja järjestelyä. Koneoppimisen avulla pystytään nopeasti keräämään ja järjestelemään sille annettua dataa, jolloin ihmiset voivat tehokkaammin hyödyntää kerättyä tietoa ennustuspäätöksissä (Jarrahi 2018, 580). Koska rullaava budjetointi mahdollistaa budjettiennusteiden päivittämisen tarvittavan usein,

pystytään myös ajoissa muuttamaan suunnitelmia ja tekemään uusia investointeja tavoitteiden saavuttamiseksi (Frow ym. 2010).

Koneoppimisalgoritmin avulla voidaan datasta löytää uusia yhtäläisyyksiä tai syy-seuraussuhteita, joita ihmispäätöksenteossa ei olla osattu ottaa huomioon. Välillä data on kuitenkin monitulkintaista tai ennustuksia joudutaan tekemään tilanteista, joista ei ole aiempaa näyttöä, jolloin koneoppimisalgoritmin toimintaa tulee tarkastella kriittisesti. (Jarrahi ym. 2018, 580.) Nykypäivän tekoäly ei ole vielä ihmistynyttä tekoälyä, jolloin se ei kykene vielä esimerkiksi sosiaalisten tekijöiden huomioimiseen (Kaplan & Haenlein 2019a, 18–19). Voi siis olla olennaista joissain tilanteissa tarkastella koneoppimisalgoritmin tuottamia tuloksia kriittisesti, etenkin jos data on monitulkintaista.

Vaikka koneoppimisalgoritmien avulla tekoäly voi löytää uusia yhteyksiä datasta, edellytyksenä on kuitenkin se, että tulevaisuutta voidaan ennustaa melko hyvin olemassa olevien tietojen perusteella (Shrestha ym. 2019, 67). Lisäksi talousjohdolla saattaa olla tulevaisuuteen suuntautuvaa tietoa, joita koneoppimisalgoritmit eivät kykene hyödyntämään (Ranta ym. 2023, 622). Jarrahi ym. (2018, 581) toteavat järkeväksi tekoälyn tehtäväksi datan läpikäynnin ja järjestelyn sen nopeuden takia, kun taas ihmisen tehtäväksi datan kokonaisvaltaisemman tarkastelun ihmisen intuitiivisen arvostelukyvyn ja näkemyksen takia. Ranta ym. (2023, 622) korostaa koneoppimisalgoritmien kykenevän käyttämään suuria datamääriä systemaattisemmin ja loogisemmin kuin talousjohtajat, jolloin niiden luomat arviot ovat potentiaalisempia kuin talousjohtajien.

4.2.2 Syväoppiminen

Jos yrityksen tavoitteena on automatisoida ennusteiden laatimista, syväoppiminen kykenee tarkempaan päätöksentekoon kuin koneoppiminen. Syväoppimisen hyötynä koneoppimiseen verrattuna on etenkin se, että se kykenee automaattisesti prosessoimaan raakaa dataa niin, ettei ihmisen tarvitse osallistua algoritmin toimintaan syöttämällä sille tiettyä dataa (Ranta ym. 2023, 608). Nykypäivänä syväoppimisalgoritmit kykenevät prosessoimaan entistä suurempia määriä dataa, joita ihminen ei kykene käsittelemään, jolloin syväoppimisalgoritmien päätöksentekotarkkuus paranee entisestään verrattuna ihmisen päätöksentekoon (Jarrahi ym. 2018, 581). Voidaan päätellä, että syväoppimisalgoritmi kykenee siis tekemään rullaavan budjetoinnin ennusteita varten tarkempia päätöksiä esimerkiksi tulevaisuuden myynnistä kuin ihminen.

Lisäksi koska syväoppiminen on koneoppimista kehittyneempi teknologia, se kykenee neuroverkkojen avulla prosessoimaan paremmin jäsentämätöntä ja epälineaarista dataa, eli dataa, jonka välillä ei ole suoria yhteyksiä (Rhanoui 2019, 319). Syväoppimista voidaan hyödyntää jäsentämättömän datan järjestelemiseen, niin, että se on helpommin ymmärrettävässä ja laskettavassa muodossa. Syväoppimisalgoritmi oppii tunnistamaan yhtäläisyyksiä monimutkaisesta datasta, esimerkiksi kuluttajien käyttäytymisestä kertovasta datasta sosiaalisen median keskustelukanavilta tai videoista, joita voidaan hyödyntää ennusteita tehdessä. (Ranta ym. 2023, 609, 615.)

Ihminen ajattelee usein hyveiden, sääntöjen ja normien avulla, kun taas tekoälyllä on valmius käsitellä erittäin monimutkaistakin dataa ja tehdä päätöksiä rationaalisesti. Tekoälyjärjestelmät ovat johdonmukaisempia kuin ihmiset, eikä niillä ole stressiä, tunteita tai taipumusta ajaa omaa etua, jotka saattavat vaikuttaa päätöksentekoon. Lisäksi tekoälyn kyky säilöä tietoa on paljon parempi kuin ihmismuistilla. (Korteling ym. 2021, 7.) Syväoppiminen etenkin hyödyntämällä LSTM-neuroverkkoja kykenee säilyttämään ”muistissa” prosessoitua dataa pitkään (Rhanoui ym. 2019, 319). Syväoppimisalgoritmi ottaa ennustuspäätöksissä huomioon vain datan, eikä sen päätöksentekoon vaikuta ulkoiset tekijät, jolloin se on rationaalisempi päätöksentekijä. Kuitenkin esimerkiksi normien, aineettomien poliittisten intressien ja muiden monimutkaisten sosiaalisten tekijöiden huomioiminen usein kannattaa ennusteita tehdessä, ja ihminen kykenee tällaisten asioiden huomioimiseen syväoppimisalgoritmia paremmin. (Jarrahi ym. 2018, 580).

Syväoppimisalgoritmi voittaa useat muut ennustusmenetelmät siinä, että se kykenee oppimaan samankaltaisia rakenteita datasta ja kykenee tunnistamaan näitä sitten uudesta datasta, josta on vain vähän tai ei lainkaan historiallista tietoa. Syväoppimisalgoritmi kykenee myös oppimaan datan kausiluonteisen käyttäytymisen, jolloin se ei vaadi manuaalista puuttumista datan määrittelyyn (Salinas ym. 2022, 1182). Kausiluonteisuus liittyy myös rullaavaan budjettiin, sillä ennusteita tehdään useampia kertoja vuodessa, jolloin syväoppimisen avulla opitaan tunnistamaan kausiluonteisia toistuvuuksia datasta ennusteita varten.

Koneoppimisalgoritmien ja etenkin syväoppimisalgoritmien menestyksenkäs käyttöönotto riippuu kuitenkin suuresti sille määritetyistä muuttujista eli parametreista², jotka vaikuttavat siihen, minkä ennustamiseen kyseinen syväoppimisalgoritmi erikoistuu. Parametrien määrittäminen on tärkeää sekä koneoppimisalgoritmin että syväoppimisalgoritmin toiminnassa tarkkojen ja haluttujen tulosten saamiseksi. Syväoppimisalgoritmissa parametreja kutsutaan hyperparametreiksi³, ja niitä on huomattavasti enemmän kuin koneoppimisalgoritmissa ja siksi niiden määrittäminen vie myös enemmän aikaa ja voi olla haastavaa. (Makridakis ym. 2022.)

Edes syväoppimisalgoritmin käyttö rullaavan budjetoinnin ennusteissa ei ole sen käyttöönottovaiheessa täysin automatisoitua, sillä sen halutun toiminnan varmistamiseksi tulee määrittää hyperparametrit oikein. Hyperparametrien määrittelyn jälkeen syväoppimisalgoritmi kykenee kuitenkin automatisoituun itsenäiseen toimintaan, eikä sille tarvitse määrätä tiettyä dataa niin kuin koneoppimisalgoritmile. Syväoppimisalgoritmit ovat hyvin tehokkaita ja tarkkoja ennustusvälineitä ja useita syväoppimisalgoritmeja yhdistelemällä tarkkuus paranee entisestään. (Makridakis ym. 2022, 853.)

Syväoppimisalgoritmien onnistuneen käyttöönottovaiheen jälkeen se voi vähentää huomattavasti taloushallinnon työvoimakustannuksia prosessin automatisoinnin ansiosta. Wangin (2022, 610) mukaan tekoälyteknologian käyttäminen voi korvata suurimman osan manuaalisesta työstä, jolloin henkilötyötunnit vähenevät 5 prosenttiin nykyisestä ja lisäksi ennusteiden virheprosentti on lähes 0. Tekoäly ei siis ainoastaan paranna ennusteiden tarkkuutta rullaavassa budjetoinnissa, vaan se vapauttaa myös työvoimakustannuksia, jolloin ne voidaan käyttää hyödyllisemmin (Wang 2022, 610).

Makridakis ym. (2022) toteavat syväoppimisalgoritmien olevan tarkempia ennustusmenetelmiä kuin koneoppimisalgoritmit tai perinteisemmät ennustusmenetelmät etenkin kuukausittaisessa ennustamisessa. Bhimani ym. (2018) on todennut kuukausittain rullaavan budjetoinnin ennusteita laativien yritysten seuraavan budjettia suuremmalla intensiteetillä, ja kuukausittain tehtävien ennusteiden sopivan paremmin epävarmoihin ympäristöihin kuin esimerkiksi neljännesvuosittain tehtävät ennusteet. Syväoppiminen

² Parametri voi olla esimerkiksi algoritmista differenssien tai liukuvien keskiarvojen lukumäärä (Rhanoui 2019, 2)

³ Hyperparametri voi olla esimerkiksi neuroverkon kerrosten tai solmujen määrä (Makridakis ym. 2022, 842)

sopii ennustusmenetelmänä siis hyvin kuukausittain tehtävään rullaavan budjetoinnin ennustamiseen.

Sopivien ja käyttäjäystävällisten syväoppimisalgoritmien sekä riittävän tietokoneiden laskentatehon puute on vaikuttanut merkittävästi siihen, ettei syväoppimisalgoritmeja ole käytetty ennustusmenetelmänä. Nykypäivänä kuitenkin valmiita algoritmeja sisältävät syväoppimismallit ovat yleistyneet, jolloin myös niiden käyttö ennustusmenetelmänä yleistyy, sillä niitä ei tarvitse rakentaa kokonaan itse. Riittää, että valmiita syväoppimisalgoritmeja muokkaa tietyille käyttäjälle sopivaksi ennustusmenetelmäksi määrittämällä hyperparametrit. (Makridakis ym. 2022, 841.)

On hyvä kuitenkin huomioida, että vaikka syväoppimisalgoritmien ennustukset ovat todettu tarkoiksi, niiden toimintaa kutsutaan usein mustaksi laatikoksi (engl. black box). Tämä tarkoittaa sitä, että ennusteiden käyttäjä ei voi suoraan ymmärtää, miten ennusteet on tehty, ja olisivatko ne olleet erilaisia, jos jotain hyperparametria olisi muutettu. (Makridakis ym. 2022, 854.) Syväoppimisalgoritmien käyttämien neuroverkkojen monimutkaisen ja läpinäkymättömän toiminnan takia niiden toiminta on vaikeasti ymmärrettävää, eikä sitä siksi myöskään koeta aina luotettavaksi (Duan ym. 2019, 66). Tekoälyn implementointi yrityksen toimintoihin voi vaatia merkittäviä investointeja ja työtapojen muuttamista (Dwivedi ym. 2021, 5). Etenkin syväoppimisen käyttöönotto voi olla yritykselle suuri investointi, jos sitä hyödynnetään koko rullaavan budjetoinnin ennustamisen automatisointiin.

4.2.3 Koneoppivan ja syväoppivan ennustusmenetelmän vertailu kahden tutkimuksen kautta

Rhanouin ym. (2019) tutkimuksessa vertaillaan koneoppimisalgoritmin ja syväoppimisalgoritmin toimintaa budjettiennusteiden laatimisessa. Tutkimuksessa rakennettiin koneoppimisalgoritmi ja syväoppimisalgoritmi, joiden avulla budjettien ennustaminen toteutettiin. Tutkimuksessa käytettiin ennustamiseen organisaation käyttämiä todellisia vuosibudjetteja vuosilta 1976–2016. Tutkimuksessa testattiin koneoppimisalgoritmin tarkkuutta käyttämällä Box-jenkins mallia, joka rakentuu aikasarjadatan tunnistusvaiheesta, estimointivaiheesta ja lopuksi diagnoosivaiheesta. Syväoppimisalgoritmin tarkkuutta testattiin LSTM-neuroverkkojen avulla, koska ne kykenevät säilyttämään prosessoitua tietoa pisimpään. Tutkimuksessa LSTM-neuroverkko rakennettiin niin, että syötekerroksessa on vain yksi solmu eli se saa yhden

syötteen ja tuotoskerroksella on vain yksi solmu eli se tuottaa yhden tuloksen, mutta piilotettujen kerrosten määrää mukailtiin.

Wangin ym, (2021) tutkimuksessa vertaillaan koneoppimisalgoritmin ja syväoppimisalgoritmin toimintaa rullaavissa kysyntäennusteissa epävarmassa ympäristössä. Tutkimuksen kohdeyritys on materiaalintoimittaja, joka kamppailee varastonhallinnan ongelmista, kuten tuotteiden kysynnän epävakaudesta ja tuotteiden laajan valikoiman hallinnoimisesta epävarmassa ympäristössä. Tutkimuksessa käytettiin ennustamiseen yrityksen dataa myyntivolyyymeistä vuosilta 2017–2019. Tutkimuksessa käytettiin Box-jenkins mallia koneoppimisalgoritmiin ja syväoppimisalgoritmiin vastaavaa LSTM-neuroverkkoa ennustamisen toteuttamiseen, kuten Rhanouin ym. (2019) tutkimuksessa.

Rhanouin ym. (2019) tutkimuksen tulokseksi saatiin, että LSTM-neuroverkkojen avulla syväoppimisalgoritmin ennustus oli tarkempi kuin koneoppimisalgoritmin ennustus. Tutkimuksessa todetaan, että LSTM-neuroverkoilla on suurta potentiaalia aikasarjojen mallinnuksessa ja ennustamisessa, kuten budjetoinnissa. LSTM-neuroverkkojen avulla voidaan asettaa lukuisia parametreja, joiden avulla voidaan ennustaa optimaalisia tuloksia. Niiden haittapuolena on se, että täytyy osata valita oikeat hyperparametrit tietylle mallille. Koneoppimisalgoritmi on helppo määrittää, mutta senkin määrittämiseen tarvitaan muutama matemaattinen parametri. Koneoppimisalgoritmi käyttää vähemmän dataa, kun taas syväoppimisalgoritmi käyttää enemmän.

Myös Wangin ym, (2021) tutkimuksessa päästiin tulokseen, että syväoppimisalgoritmi LSTM-neuroverkkojen avulla on sopivampi kohdeyrityksen ennustamisjärjestelmäksi kuin koneoppimisalgoritmi, koska sillä oli pienin ennustusvirhe lyhyen aikavälin rullaavissa ennusteissa. Tutkimuksessa korostetaan sitä, että koneoppimisalgoritmimalli on yksinkertainen, ja se vaatii vähemmän muuttujia, mutta data täytyy koneoppimisalgoritmimallia varten järjestää tiettyyn muotoon, eli esimerkiksi datan täytyy olla järjestely kolumneihin ja riveihin tasaisesti. Lisäksi koneoppimisalgoritmi huomioi vain datan lineaariset suhteet eikä epälineaarisia toisin kuin syväoppimisalgoritmi. Syväoppimisalgoritmi täydentää koneoppimisalgoritmin haittoja, mutta sen haittapuolena taas on hyperparametrien asettamisen monimutkaisuus, kuten Rhanouin ym. (2019) tutkimuksessakin todettiin.

Rhanouin ym. (2019) tutkimuksessa todetaan, että optimaalisen budjetointiennusteita tekevän mallin määrittäminen on haastavaa, koska data on usein epälineaarista ja omaa suuren volatiliteetin eli keskinäisen vaihtelun. Yhtenä vuonna myynti on siis voinut olla esimerkiksi todella suurta ja toisena taas todella pientä, joka tekee datasta vaikeammin ennustettavaa. Vaikka tutkimuksessa saatiin tyydyttäviä tuloksia myös koneoppimisalgoritmin avulla, syväoppimisalgoritmi kykeni ennustamaan koneoppimisalgoritmia huomattavasti tarkemmin.

Nämä tutkimukset tukevat tutkielmassa tehtyjä havaintoja, sillä syväoppimisalgoritmit kykenevät koneoppimista paremmin käymään läpi epälineaarista ja jäsentämätöntä dataa ja toimivat juuri ennustamispäätöksenteossa paremmin, kun taas koneoppimisalgoritmillla voi olla enemmän hyötyjä jäsenneilyn datan järjestelemisessä riippuen yrityksen tavoitteista hyödyntää tekoälyä rullaavan budjetoinnin ennusteissa. Voidaan olettaa, että näiden tutkimusten tulokset soveltuvat myös rullaavan budjetoinnin ennusteisiin, vaikka ne eivät suoraan tutki rullaavan budjetoinnin ennusteita, mutta tutkivat koneoppimista ja syväoppimista dataa käyttävinä ennustusmenetelminä.

On kuitenkin tärkeää, että tutkimuksia tehdään enemmän rullaavan budjetoinnin osalta, koska rullaaviin budjetteihin otetaan usein huomioon esimerkiksi monia muuttuvia kustannuksia, kun taas Wangin ym. (2021) tutkimus tutki ainoastaan kysyntäennustamista myyntidatasta ja Rhanouin ym. (2019) tutkimus tutki vuosibudjettien ennustamista. Täytyy myös tiedostaa, että tutkimukset muodostettiin vertaamalla tekoälyllä tehtyjä ennusteita toteutuneisiin lukuihin, mutta eivät olleet esimerkki tekoälyn käyttämisestä budjettien ennusteissa oikeiden yritysten toiminnassa.

Tässä luvussa tarkasteltiin tekijöitä, jotka ovat edellytyksenä sille, että tekoälyä voidaan hyödyntää yrityksissä sekä tekijöitä, joita tulee ottaa huomioon tekoälyn käyttöönotossa. Tekoälyn käyttöönoton ja nopean kehityksen on mahdollistanut big datan lisääntyminen sekä tietotekniikkaosaamisen kehittyminen, vaikka nopea kehitys tuleekin hidastumaan tietoteknisten fyysisten rajoitteiden takia. Tekoälyn käyttö on välttämätöntä kilpailuedun säilyttämiseksi epävarmoissa ympäristöissä sen tarkan päätöksenteko- ja datan prosessointikyvyn takia. Tekoälyn käyttöönotto organisaatioissa vaatii muutoksensietokykyä sekä joustavuutta niin johdossa, työntekijöissä kuin asiakkaissa.

Luvussa keskityttiin etsimään vastauksia tutkimuskysymyksiin tutkimalla tekoälyn hyödyntämistä rullaavan budjetoinnin ennusteissa. Tarkastelu toteutettiin koneoppimisen

ja syväoppimisen tekoälyteknologioiden kautta tarkastellen näitä siitä näkökulmasta, missä roolissa yritys haluaa käyttää tekoälyä osana rullaavan budjetoinnin ennustamista ja kuinka paljon dataa yrityksellä on käytettävänä. Jos yrityksessä talousjohto haluaa käyttää tekoälyä osana rullaavan budjetoinnin ennusteita, mutta haluaa silti säilyttää asemansa mukana päätöksentekoa, koneoppiminen on hyödyllinen jäsennellyn datan tehokkaassa läpikäymisessä ja sen järjestelemisessä, jonka pohjalta ihminen kykenee tekemään tehokkaammin ennusteita. Jos talousjohto taas haluaa antaa tekoälylle enemmän valtaa ennustamisessa, monimutkaisemmat syväoppimisalgoritmit kykenevät parempaan ennustustarkkuuteen ja itsenäisempään toimintaan niiden määrittämis- ja käyttöönottovaiheen jälkeen. Lisäksi syväoppimisalgoritmi on parempi jäsentämättömän datan läpikäymisessä. Kahden esitetyn tutkimuksen perusteella voidaan myös todeta syväoppimisalgoritmin kykenevän tarkempien ennusteiden laatimiseen rullaavassa budjetoinnissa.

5 Yhteenveto ja johtopäätökset

Tutkielman tarkoituksena oli tutkia tekoälyn käyttöä rullaavan budjetoinnin ennusteissa keskittyen erityisesti koneoppimiseen ja syväoppimiseen, jotka ovat ennustamisen kannalta olennaisimmat tekoälyteknologiat. Tavoitteena oli jakaa koneoppimisen ja syväoppimisen käyttömahdollisuuksia yrityksen preferenssien ja käytettävissä olevan datan perusteella rullaavan budjetoinnin ennusteissa.

Tutkielmassa hyödynnettiin aiheen tarkastelemiseen alan kirjallisuutta ja sovellettiin jo aikaisemmin toteutettuja tutkimuksia. Aikaisemmat tutkimukset ovat tarkastelleet tekoälyn käyttöä perinteisessä budjetoinnissa tai tekoälyteknologioita ennustamismenetelminä, joten tässä tutkielmassa on sovellettu aikaisempia tutkimuksia sopimaan rullaavan budjetoinnin ennustamiseen. Yhtenevä näkemys kirjallisuuden ja tutkimusten pohjalta on, että tekoälyn käytöllä on potentiaalia ennustamisessa sekä datan järjestelmissä, mutta tutkimusta ja konkreettista toteutusta tarvitaan vielä lisää.

Tutkielman tavoitetta selvitettiin seuraavien tutkimuskysymysten kautta:

1. Miten tekoälyä voidaan hyödyntää rullaavan budjetoinnin ennusteissa?
 - a. Mitkä ovat tekoälyn käyttöönoton edellytykset?
 - b. Mitkä ovat koneoppivan ja syväoppivan järjestelmän hyötyjen keskeiset erot rullaavan budjetoinnin ennusteiden kannalta?

Tutkielmassa todettiin, että tekoälyn käyttöönottoon edellytyksenä voidaan pitää sekä yrityksen sisäistä että ulkoista luottamusta, muutosta ja kontrollia. Yrityksen johdolla täytyy olla luottamus työntekijöitä kohtaan muuttuvassa ympäristössä, ja kuluttajilla täytyy olla luottamus organisaation tekoälyjärjestelmän kykyihin. Työntekijöiden täytyy jatkuvasti mukautua uusiin tehtäviin ja kehittää taitojaan jatkuvalla oppimisella. Kilpailijoita tulee pystyä tarkkailemaan sekä kilpailemaan paremman laitteiston ja tiedon avulla. Sisäisesti on kyettävä valvomaan tekoälykoneita, jotta vältetään niiden vinoumat sekä kyettävä ohjaamaan niitä autonomiseen toimintaan. Ulkoisesti on valtioiden tehtävä valvoa johtajien, työntekijöiden, koneiden, kuluttajien ja kilpailijoiden ekosysteemiä. (Kaplan & Haenlein 2019a, 20.) Tekoälyn käyttöönoton edellytyksinä voidaan pitää myös tarvittavaa määrää dataa, jotta se voidaan kouluttaa sekä riittävää laskentateho infrastruktuuria käytettävissä koneissa (Duan ym. 2019, 63).

Tutkielman mukaan koneoppimisen käyttämiselle rullaavan budjetoinnin ennusteissa on hyötyä silloin, kun yritys haluaa säilyttää aseman päätöksenteossa, eikä automatisoida ennustamista kokonaan tekoälyä käyttämällä. Eniten hyötyä koneoppimisalgoritmita on jäsenneilyn datan prosessoinnissa, koska se kykenee syväoppimisalgoritmia paremmin prosessoimaan jäsenneilyä dataa. Tärkein rullaavan budjetoinnin ennusteissa käytettävä data on suurimmilta osin yrityksen sisäisiä datakokonaisuuksia, jotka ovat jäsenneilyssä muodossa. (Ranta ym. 2023, 622). Koneoppimisen avulla pystytään käymään läpi nopeasti dataa ja poimimaan sieltä tärkeimpiä yhteyksiä, joita ihmiset voivat käyttää tehokkaasti ennustuspäätöksissä (Jarrahi 2018, 581). Rullaava budjetointi taas mahdollistaa ennusteiden päivittämisen tarvittavan usein (Frow ym. 2010). Koneoppimisen avulla säästetään siis aikaa rullaavan budjetoinnin ennustamisessa, sillä ihmiset voivat keskittyä käyttämään koneoppimisalgoritmin järjestelmää dataa jatkuvissa ennustuspäätöksissä.

Koneoppimisalgoritmi ei kuitenkaan kykene toimimaan yhtä tarkkana ennustusmenetelmänä kuin syväoppimisalgoritmi (Wang 2021; Rhanoui ym. 2019). Syväoppimisalgoritmin vahvuudeksi osoittautuikin tutkielman perusteella sen kyky käsitellä suuria määriä jäsentämätöntä dataa ja toimia tarkkana ennustusmenetelmänä. Syväoppimisen hyötynä on etenkin se, että se kykenee automaattisesti prosessoimaan raakaa dataa niin, ettei ihmisen tarvitse osallistua algoritmin toimintaan syöttämällä sille tiettyä dataa (Ranta ym. 2023, 608). Se kykenee myös käsittelemään suurempia määriä dataa kuin ihminen, jolloin syväoppimisavusteiseen ennustamiseen otetaan huomioon enemmän dataa kuin ihmisen tekemään ennustamiseen (Jarrahi ym. 2018).

Syväoppimisalgoritmin käyttämät LSTM-neuroverkot ovat ennustamiseen soveltuvia, koska niiden avulla prosessoitua dataa voidaan säilyttää ikään kuin muistissa (Rhanoui ym. 2019, 319). Lisäksi syväoppimisalgoritmin avulla voidaan oppia samankaltaisia rakenteita datasta, jolloin myös sellaisten asioiden ennustaminen helpottuu, joista ei ole ennalta historiallista tietoa. (Salinas ym. 2022, 1182). Syväoppimisalgoritmin avulla rullaavan budjetoinnin ennustamisprosessi voidaan automatisoida, ja ennustuksissa voidaan käyttää myös jäsentämätöntä dataa, jolloin tekoäly ylittää ihmisen ennustamiskyvyn.

Tutkielman perusteella tekoälyn mahdollisuudet rullaavan budjetoinnin ennusteissa ovat kiteytetysti datan läpikäymisen ja järjestelyn nopeutuminen, uusien syy-seuraussuhteiden

ja yhteyksien löytäminen datasta sekä tarkkojen ennusteiden laatiminen. Tekoälyn avulla koko rullaavan budjetoinnin ennustaminen voidaan tarvittaessa automatisoida, jolloin ihmisen työksi jää ainoastaan käytetyn tekoälyjärjestelmän muokkaaminen yritykselle siihen tehtävään sopivaksi. Koneoppimisalgoritmin parametrit ja syväoppimialgoritmin hyperparametrit täytyy määrittää ennen niiden käyttöönottoa, mutta määrittämisen jälkeen ihmisen ei tarvitse puuttua tekoälyn toimintaan, ja rullaavan ennustamisen jatkuva ennustustyö voidaan automatisoida (Makridakis ym. 2022).

Rullaavan budjetoinnin ennustamisessa on tärkeää, että käytetään paljon saatavilla olevaa dataa. Tekoälyn avulla big dataa voidaan hyödyntää tehokkaasti (Wang 2022), jolloin se päihittää ihmisen kyvyn prosessoida dataa. Tekoälyn avulla voidaan tehdä myös järjestelmällisempiä päätöksiä, koska tekoälyn tekemiin päätöksiin ei vaikuta esimerkiksi tunteet tai stressi (Korteling ym. 2021, 7). Täytyy kuitenkin ottaa huomioon, että nykypäivän tekoäly ei ole vielä ihmistynyttä tekoälyä eli se ei kykene sosiaalisten tekijöiden huomioimiseen (Kaplan & Haenlein 2019a, 18–19), eikä tekoälyllä ole välttämättä saatavilla kaikkea ennustamisessa huomioonotettavaa tietoa (Ranta ym. 2023, 622).

Tutkielmasta on hyötyä yrityksille, jotka haluavat käyttää tekoälyä rullaavan budjetoinnin ennusteissa yrityksen preferenssien mukaisesti. Tämä tutkielma osoittaa, että tekoälyllä on potentiaalia datan tehokkaassa prosessoinnissa ja tarkkana ennustamismenetelmänä.

Tutkielman aiheesta ei löytynyt kirjallisuudesta suoraa tutkimuksia, joten aihetta tulee tutkia vielä enemmän tarkempien tulosten saamiseksi. Tulevaisuudessa rullaavan budjetoinnin mahdollisesti yleistyessä entistä enemmän, tekoälyä saatetaan implementoida juuri rullaavan budjetoinnin prosesseihin ja osaksi ennustamista. Tekoäly näyttää kasvavan teknologiana ja voi olla, että tulevaisuudessa sitä käytetään monien yrityksen liiketoimintaprosessien tukena. Mahdolliseksi haasteeksi voi koitua kuitenkin tekoälyä koskeva sääntely, joka on vasta kehitysvaiheessa. Tutkielma kannustaa jatkotutkimukselle, sillä aihetta on tutkittu hyvin vähän ja empiiristä tutkimusta tekoälyn käytöstä rullaavan budjetoinnin ennusteissa ei vielä ole. Lisäksi jatkotutkimukset voisivat tutkia mahdollisia haasteita, joita tekoälyn käyttöönottoon ja käyttämiseen liittyy.

Lähteet

- Asogwa, I. E. – Etim, O. E. (2017) Traditional budgeting in today's business environment. *Journal of Applied Finance and Banking*, Vol. 7 (3), 111–120.
- Bakarich, K. M. – O'Brien, P. E. (2021) The robots are coming... but aren't here yet: The use of artificial intelligence technologies in the public accounting profession. *Journal of Emerging Technologies in Accounting*, Vol. 18 (1), 27–43.
- Bhimani, A. – Horngren, C. T. – Datar, S. M. – Rajan, M. V. (2019) *Management and cost accounting*. Pearson Education Limited, Harlow.
- Bhimani, A. – Sivabalan, P. – Soonawalla, K. (2018) A study of the linkages between rolling budget forms, uncertainty and strategy. *British Accounting Review*, Vol. 50 (3), 306–323.
- Chen, Y. – Biswas, M. I. – Talukder, M. S. (2023) The role of artificial intelligence in effective business operations during COVID-19. *International Journal of Emerging Markets*, Vol. 18 (12), 6368–6387.
- Cho, S. – Vasarhelyi, M. A. – Sun, T. – Zhang, C. (2020) Learning from machine learning in accounting and assurance. *Journal of Emerging Technologies in Accounting*, Vol. 17 (1), 1–10.
- Duan, Y. – Edwards, J. S. – Dwivedi, Y. K. (2019) Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *International Journal of Information Management*, Vol. 48, 63–71.
- Dwivedi, Y. K. – Hughes, L. – Ismagilova, E. – Aarts, G. – Coombs, C. – Crick, T. – Duan, Y. – Dwivedi, R. – Edwards, J. – Eirug, A. – Galanos, V. – Ilavarasan, P. V. – Janssen, M. – Jones, P. – Kar, A. K. – Kizgin, H. – Kronemann, B. – Lal, B. – Lucini, B. – Medaglia, R. – Le Meunier-FitzHugh, K. – Le Meunier-FitzHugh, L. C. – Misra, S. – Mogaji, E. – Sharma, S. K. – Singh, J. B. – Raghavan, V. – Raman, R. – Rana, N. P. – Samothrakakis, S. – Spencer, J. – Tamilmani, K. – Tubadji, A. – Walton, P. – Williams, M. D. (2021) Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, Vol. 57.

- Ekholm, B. G. – Wallin, J. (2011) The impact of uncertainty and strategy on the perceived usefulness of fixed and flexible budgets. *Journal of Business Finance and Accounting*, Vol. 38 (1–2), 145–164.
- Euroopan komissio (2018) Big Data. <<https://digital-strategy.ec.europa.eu/en/policies/big-data>>, haettu 28.2.2024.
- Euroopan parlamentti (2023) Mitä tekoäly on ja mihin sitä käytetään? <<https://www.europarl.europa.eu/topics/fi/article/20200827STO85804/mita-tekoaly-on-ja-mihin-sita-kaytetaan>>, haettu 28.2.2024.
- Frow, N. – Marginson, D. – Ogden, S. (2010) ”Continuous” budgeting: Reconciling budget flexibility with budgetary control. *Accounting, Organizations and Society*, Vol. 35 (4), 444–461.
- Fülöp, M. T. – Topor, D. I. – Ionescu, C. A. – Cifuentes-Faura, J. – Măgdaş, N. (2023) Ethical concerns associated with artificial intelligence in the accounting profession: A curse or a blessing? *Journal of Business Economics and Management*, Vol. 24 (2), 387–404.
- Goodfellow, I. – Bengio, Y. – Courville, A. (2016) *Deep learning*. MIT Press, London.
- Hill, R. K. (2016) What an algorithm is. *Philosophy & Technology*, Vol. 29 (1), 35–59.
- Ikäheimo, S – Malmi, T– Walden, R (2019) *Yrityksen laskentatoimi*. Alma Talent Oy, Helsinki.
- Jarrahi, M. H. (2018) Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, Vol. 61 (4), 577–586.
- Kaplan, A. – Haenlein, M. (2019a) Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, Vol. 62 (1), 15–25.
- Kaplan, A. – Haenlein, M. (2019b) A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *California Management Review*, Vol. 61 (4), 5–14.
- Kaplan, A. – Haenlein, M. (2020) Rulers of the world, unite! The challenges and opportunities of artificial intelligence. *Business Horizons*, Vol. 63 (1), 37–50.
- Kihn, L (2023) Budgeting changes and success: abandonment, reform or stability in Finnish manufacturing firms? *Journal of Accounting and Organizational Change*, Vol. 19 (6), 91–111.

- Korteling, J. E. – van de Boer-Visschedijk, G. C. – Blankendaal, R. A. M. – Boonekamp, R. C. – Eikelboom, A. R. (2021) Human- versus Artificial Intelligence. *Frontiers in Artificial Intelligence*, Vol. 4.
- Kreutzer, R. T. – Sirrenberg, M. (2019) *Understanding Artificial Intelligence*. Springer Nature Switzerland AG, Cham.
- Kufel, J. – Bargieł-Łączek, K. – Kocot, S. – Koźlik, M. – Bartnikowska, W. – Janik, M. – Gruszczyńska, K. (2023) What is machine learning, artificial neural networks and deep learning?—Examples of practical applications in medicine. *Diagnostics*, Vol. 13 (15).
- Kumar, V. – Rajan, B. – Venkatesan, R. – Lecinski, J. (2019) Understanding the Role of Artificial Intelligence in Personalized Engagement Marketing. *California Management Review*, Vol. 61 (4), 135–155.
- Makridakis, S. – Spiliotis, E. – Assimakopoulos, V. – Semenoglou, A.-A. – Mulder, G. – Nikolopoulos, K. (2023) Statistical, machine learning and deep learning forecasting methods: Comparisons and ways forward. *The Journal of the Operational Research Society*, Vol. 74 (3), 840–859.
- Malviya, A. – Malmgren, M. (2018) *Big Data for Managers: Creating Value*. Routledge, Boca Raton.
- McCarthy, J. – Minsky, M. L. – Rochester, N. – Shannon, C. E. (2006) A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence: August 31, 1955. *The AI Magazine*, Vol. 27 (4), 12–14.
- Neely, A. – Bourne, M. – Adams, C. (2003) Better budgeting or beyond budgeting? *Measuring Business Excellence*, Vol. 7 (3), 22–28.
- Neilimo, K– Uusi-Rauva, E (2005) *Johdon laskentatoimi*. Edita, Helsinki.
- Pellinen, J (2017) *Talousjohtaminen*. Alma Talent Oy, Helsinki.
- Ranta, M. – Ylinen, M. – Järvenpää, M. (2023) Machine learning in management accounting research: Literature review and pathways for the future. *The European Accounting Review*, Vol. 32 (3), 607–636.
- Rhanoui, M. – Yousfi, S. – Mikram, M. – Merizak, H. (2019) Forecasting financial budget time series: Arima random walk vs lstm neural network. *IAES International Journal of Artificial Intelligence*, Vol. 8 (4), 317–327.
- Salinas, D. – Flunkert, V. – Gasthaus, J. – Januschowski, T. (2020) DeepAR: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*, Vol. 36 (3), 1181–1191.

- Saha, S. – Gan, Z. – Cheng, L. – Gao, J. – Kafka, O. L. – Xie, X. – Li, H. – Tajdari, M. – Kim, H. A. – Liu, W. K. (2021) Hierarchical Deep Learning Neural Network (HiDeNN): An artificial intelligence (AI) framework for computational science and engineering. *Computer Methods in Applied Mechanics and Engineering*, Vol. 373.
- Sestino, A. – De Mauro, A. (2022) Leveraging artificial intelligence in business: Implications, applications and methods. *Technology Analysis and Strategic Management*, Vol. 34 (1), 16–29.
- Shrestha, Y. R. – Ben-Menahem, S. M. – von Krogh, G. (2019) Organizational decision-making structures in the age of artificial intelligence. *California Management Review*, Vol. 61 (4), 66–83.
- Syam, N. – Sharma, A. (2018) Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice. *Industrial Marketing Management*, Vol. 69, 135–146.
- Wallander, J (1999) Budgeting — an unnecessary evil. *Scandinavian Journal of Management*, Vol. 15 (4), 405–421.
- Wamba-Taguimdje, S. L. – Fosso Wamba, S. – Kala Kamdjoug, J. R. – Tchatchouang Wanko, C. E. (2020) Influence of artificial intelligence (AI) on firm performance: The business value of AI-based transformation projects. *Business Process Management Journal*, Vol. 26 (7), 1893–1924.
- Wang, C.-C. – Chien, C.-H. – Trappey, A. J. C. (2021) On the application of ARIMA and LSTM to predict order demand based on short lead time and on-time delivery requirements. *Processes*, Vol. 9 (7), 1157.
- Wang, F (2022) AI-enabled IT capability and organizational performance. *Systems Research and Behavioral Science*, Vol. 39 (3), 609–617.
- Zhang, G. – Eddy Patuwo, B. – Y. Hu, M. (1998) Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, Vol. 14 (1), 35–62.
- Åkerberg, P (2017) *Budjetointi 2020-luvulla*. Alma Talent Oy, Helsinki.