TURUN YLIOPISTO
Kauppakorkeakoulu

Lisätty analytiikka organisaation päätöksenteossa

Tietojärjestelmätieteen kandidaatintutkielma

Laatija:
Johannes Lankoski

Ohjaaja:
FT Kai Kimppa

11.12.2024
Turku

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

Kanditutkielma

Oppiaine: Tietojärjestelmätiede
Tekijä: Johannes Lankoski
Otsikko: Lisätty analytiikka organisaation päätöksenteossa
Ohjaaja: FT Kai Kimppa
Sivumäärä: 33 sivua
Päivämäärä: 11.12.2024

Teknologian kehitys ja datan määrän ja kompleksisuuden lisääntyminen ovat johtaneet liiketoimintatiedon hallinnan merkityksen kasvuun. Lisätty analytiikka yhdistää liiketoimintatiedon hallintaan tekoälyn eri sovelluksia, kuten koneoppimisen ja luonnollisen kielen käsittelyn. Tämä mahdollistaa massadatan tehokkaamman hyödyntämisen organisaation päätöksenteossa, mikä puolestaan tuo liiketoimintahyötyjä. Lisättyä analytiikkaa voidaan hyödyntää muun muassa automatisoimalla päätöksenteko- ja analytiikkaprosesseja. Tämä johtaa tehokkaampaan resurssien hyödyntämiseen ja laadukkaampaan päätöksentekoon. Tutkimus lisätyn analytiikan vaikutuksista organisaation päätöksentekoon on vielä kovin vähäistä.

Tässä tutkielmassa tarkastellaan lisätyn analytiikan vaikutuksia organisaation päätöksentekoon. Tutkimuksen kohteena ovat lisätyn analytiikan erot perinteiseen liiketoimintatiedon hallintaan sekä lisätyn analytiikan hyödyntäminen päätöksenteossa ja siihen liittyvät haasteet ja mahdollisuudet. Tutkielmassa käsitellään lisättyyn analytiikkaan liittyviä tekoälyn sovelluksia, kuten koneoppimista ja neuroverkkoja, sekä erilaisia organisaation päätöksentekorakenteita ja -malleja. Tutkimus on toteutettu kirjallisuuskatsauksena, jossa on hyödynnetty aiheeseen liittyviä tieteellisiä artikkeleita.

Lisätty analytiikka mahdollistaa automaation liiketoiminta-analytiikkasyklin työläimmissä vaiheissa, eli datan valmistelussa ja analysoinnissa. Tämä säästää merkittävästi aikaa ja vapauttaa resursseja muihin prosessin vaiheisiin. Joitakin liiketoiminta-analytiikkasyklin vaiheita, kuten päätöksentekoa, ei voi vielä automatisoida kokonaan, mutta näissäkin vaiheissa lisätty analytiikka mahdollistaa tehokkuuden lisäämisen ja laadun parantamisen.

Lisätty analytiikka tuo merkittävää hyötyä liiketoimintaan, erityisesti päätöksentekoon operatiivisella tasolla. Taktisella ja erityisesti strategisella päätöksentekotasolla lisätyn analytiikan hyödyt ovat rajallisemmat. Lisätyn analytiikan käyttöön liittyy kuitenkin myös haasteita. Tekoälyalgoritmit saattavat sisältää vinoumia ja eettisten ongelmien huomioiminen voi olla haastavaa. Lisätyn analytiikan onnistunut hyödyntäminen vaatii muun muassa algoritmien läpinäkyvyyden lisäämistä sekä tekoälyn ja ihmisen yhteistyötä. Vastuu päätöksistä on aina ihmisellä, vaikka päätökset olisikin tehnyt tekoälyä hyödyntävä työkalu.

Avainsanat: Lisätty analytiikka, liiketoimintatiedon hallinta, tekoäly, päätöksenteko.

SISÄLLYS

1 Johdanto 6

2 Lisätty analytiikka 7

2.1 Liiketoimintatiedon hallinta 7

2.2 Tekoälyn kyvykkyyksien kehittyminen 8

2.3 Tekoäly lisätyssä analytiikassa 12

3 Lisätyn analytiikan käyttö organisaation päätöksenteossa 14

3.1 Organisaation päätöksenteon luokittelu 14

3.2 Lisätyn analytiikan käyttötavat ja -kohteet 16

3.2.1 Lisätty analytiikka päätöksentekorakenteissa 16

3.2.2 Lisätty analytiikka liiketoiminta-analytiikkasyklin eri vaiheissa 17

3.3 Lisätyn analytiikan käytön onnistumisen edellytykset 21

3.3.1 Arvon luominen lisätyllä analytiikalla 21

3.3.2 Rajoitukset ja riskit 22

4 Yhteenveto ja johtopäätökset 25

Lähteet 29

KUVIOT

Kuva 1 Tekoälyn käsitteiden hierarkia, muokattu lähteestä (Kreutzer & Sirrenberg, 2020) 12

Kuva 2 Organisaation päätöksentekotasojen rakenteellisuus, muokattu lähteestä Edwards ym. (2000) 15

Kuva 3 Liiketoiminta-analytiikkasykli, muokattu lähteestä (Prat, 2019) 18

Kuva 4 Lisätyn analytiikan vaikutukset organisaation päätöksentekoon 28

TAULUKOT

Taulukko 1 Tekoälyn hyödyntäminen liiketoiminta-analytiikkasyklin eri vaiheissa, muokattu lähteestä Prat (2019). 20

Taulukko 2 Lisätyn analytiikan ja perinteisen liiketoimintatiedon hallinnan eroja 26

1 Johdanto

Liiketoimintatiedon hallinnan (engl. business intelligence, BI) merkitys on kasvanut viime vuosina merkittävästi massadatan (engl. big data) myötä (Chen ym., 2012). Massadatan myötä myös datan kompleksisuus on lisääntynyt, eivätkä perinteiset BI-työkalut ole enää riittävän tehokkaita massadata-analytiikkaan (engl. big data analytics). Tämän takia BI-järjestelmissä hyödynnetään yhä enemmän tekoälyä (engl. artificial intelligence, AI) analyysin eri vaiheissa. Tätä liiketoimintatiedon hallinnan ja edistyneiden tekoälysovellusten yhdistämistä kutsutaan lisätyksi analytiikaksi (engl. augmented analytics, AA). (Alghamdi & Al-Baity, 2022.) Analytiikkaprosessien automatisointi optimoi massadatan hyödyntämisen päätöksenteossa. Lisättyä analytiikkaa käyttämällä voidaan automatisoida joitain analytiikkaprosesseja kokonaan. Sellaisissa prosesseissa, joita ei ainakaan vielä voida automatisoida kokonaan, lisätty analytiikka toimii ihmisen päätöksentekoa tukevana työkaluna. (Prat, 2019.)

Shresthan ym. (2019) mukaan päätöksentekoa tukevien algoritmien rooli organisaatiossa on noussut avainasemaan. Massadatan oikeaoppinen hyödyntäminen mahdollistaa organisaatioille merkittäviä kilpailuetuja ja parannuksia muun muassa päätöksentekoon (Chen ym., 2012). Ghasemaghaein ym. (2018) mukaan tämä vaatii organisaatioilta ponnisteluja analytiikan hyödyntämisessä, jotta ne voivat tehdä nopeampia ja paremmin informoituja päätöksiä.

Tässä tutkielmassa käsitellään lisätyn analytiikan vaikutuksia organisaation päätöksentekoon. Tutkielmassa käsitellään, mitä lisätty analytiikka on, miten sitä voidaan hyödyntää päätöksenteossa sekä millaisia haasteita ja mahdollisuuksia se tuo verrattuna perinteisiin liiketoimintatiedon hallinnan ratkaisuihin.

Tutkielman tutkimuskysymykset ovat seuraavat:

1. Mitä on lisätty analytiikka ja miten se eroaa perinteisestä liiketoimintatiedon hallinnasta?
2. Miten lisätyn analytiikan käyttö vaikuttaa organisaation päätöksentekoon?
    a. Miten lisättyä analytiikkaa voi hyödyntää päätöksenteossa?
    b. Mitä lisätyn analytiikan onnistunut hyödyntäminen vaatii?

2 Lisätty analytiikka

2.1 Liiketoimintatiedon hallinta

1990-luvulta lähtien liiketoimintatiedon hallinnan ja siihen liittyvän massadata-analytiikan merkitys on kasvanut merkittävästi sekä yritysmaailmassa että akateemisessa tutkimuksessa (Chen ym., 2012). Liiketoimintatiedon hallinta tarkoittaa raakadatan jalostamista hyödylliseksi informaatioksi, jota voidaan hyödyntää esimerkiksi organisaation päätöksenteossa. Liiketoimintatiedon hallintaa pidetään oleellisena osana yrityksen arvon kasvattamista. (Duan & Xu, 2012.) Liiketoimintatiedon hallinta on käynyt läpi useita aikakausia, jotka Alghamdi ja Al-Baity (2022) jakavat kolmeen merkittävimpään sukupolveen: BI 1.0, BI 2.0 ja BI 3.0.

1980- ja 1990-luvun BI 1.0 oli liiketoimintatiedon hallinnan ensiaskel, jossa Chenin ym. (2012) mukaan keskeisessä roolissa olivat tietovarastot (engl. data warehouse). Tietovarastojen lisäksi Alghamdi ja Al-Baity (2022) mainitsevat ensimmäisen liiketoimintatiedon hallinnan sukupolven tunnusmerkeiksi päätöksentukijärjestelmät (engl. decision support system, DSS) ja yksinkertaiset tilastolliset menetelmät. Raportointi oli hidasta eikä ad hoc -raportointia harrastettu. Ensimmäisen BI-sukupolven aikana liiketoimintatiedon hallinnasta vastasi lähinnä vain IT-henkilöstö, joka esimerkiksi toteutti kyselyt muun henkilöstön puolesta. (Alghamdi & Al-Baity, 2022.)

BI 2.0 rakentui 2000-luvulla ensimmäisen BI-sukupolven luomien perusteiden päälle laajentamalla tietovarastojen ja muiden teknologioiden hyödyntämistä ja tuomalla analytiikan osaksi liiketoimintatiedon hallintaa (Alghamdi & Al-Baity, 2022). Chen ym. (2012) pitävät BI 2.0:n tärkeimpinä tunnusmerkkeinä itsepalvelu-BI:tä (engl. self-serivce BI) ja massadata-analytiikkaa. Itsepalvelu-BI:llä viitataan ei-teknisten käyttäjien mahdollisuuteen käyttää BI-työkaluja datan analysointiin ja havaintojen tekemiseen. Tämä on tehostanut analytiikkaprosesseja merkittävästi sallimalla henkilöstön toteuttaa ad hoc -kyselyitä ilman IT-osaston apua, mikä on puolestaan vapauttanut IT-henkilöstön keskittymään haastavampiin ja enemmän arvoa tuottaviin työtehtäviin. (Alghamdi & Al-Baity, 2022.)

Viimeisin sukupolvi BI 3.0 sai alkunsa 2010-luvulla ja se jatkuu yhä. BI 3.0 edustaa lisätyn analytiikan aikakautta laajentaen itsepalvelu-BI:tä entisestään siten, että myös tavallisilla käyttäjillä on mahdollisuus hyödyntää edistynyttä analytiikkaa (engl. advanced analytics) (Prat, 2019). Alghamdin ja Al-Baityn (2022) mukaan liiketoimintatiedon hallinnan kolmannen sukupolven tunnusmerkkejä ovat automaatio ja siihen hyödynnettävät teknologiat, kuten koneoppiminen (engl.

machine learning, ML), luonnollisen kielen käsittely (engl. natural language processing, NLP) ja luonnollisen kielen generointi (engl. natural language generation, NLG).

Datan lisääntyneen kompleksisuuden vuoksi perinteisiä BI-menetelmiä hyödyntävät yritykset joutuvat tekemään valinnan sen välillä, uhraavatko ne suuren määrän aikaa ja muita resursseja saadakseen riittävän syvällisen analyysin datasta, vai antavatko ne havaintojen laadun kärsiä rajoittamalla analyysiä suppeammaksi. Datan valmistelu ja järjestely perinteisillä BI-menetelmillä ei ole ainoastaan hidasta vaan myös laadullisesti heikompaa, sillä ihmiseltä saattaa jäädä havaitsematta kaavoja, jotka tekoäly olisi havainnut. (Alghamdi & Al-Baity, 2022.)

BI 1.0 antoi organisaatioille mahdollisuuden tehdä merkittäviä havaintoja strukturoidusta datasta, jota kerättiin erilaisten yritysjärjestelmien avulla. BI 2.0 ja BI 3.0 -sukupolvien tarjoamien teknologisten kehitysaskelten myötä havaintoja voidaan poimia myös strukturoimattomasta datasta. (Chen ym., 2012; Prat, 2019.) Datan määrän kasvun vuoksi perinteinen manuaalisesti toteutettava analytiikka on vaikeutunut huomattavasti. Tästä syystä lisätyn analytiikan suosio on kasvussa, ja useat yritykset hakevat strategista kilpailuetua investoimalla lisättyyn analytiikkaan. (Alghamdi & Al-Baity, 2022.)

2.2 Tekoälyn kyvykkyyksien kehittyminen

Enholmin ym. (2022) mukaan tekoälyn viimeaikaisesta suosiosta huolimatta käsitteeseen liittyy edelleen vahvaa epäselvyyttä. Wamba-Taguimdjen ym. (2020) mukaan tekoäly sisältää monia erilaisia teknologioita, mutta sen voi yleistää tarkoittamaan sitä, että kehitetään koneille mahdollisuus simuloida ihmiselle ominaisia kognitiivisia kykyjä. Enholm ym. (2022) viittaavat aiempaan kirjallisuuteen todetessaan, että tutkijoiden välillä on erimielisyyksiä siitä, kuuluuko tekoälyyn koneen kyky tehdä asioita, joita sitä ei ole varta vasten ohjelmoitu tekemään. Heidän mukaansa osa tutkijoista on sitä mieltä, että tekoäly tarkoittaa työkalua, joka pystyy ratkaisemaan ihmiselle liian paljon aikaa vievän tai jopa mahdottoman tehtävän. Kaplan ja Haenlein (2019) määrittelevät tekoälyn järjestelmän kyvykkyydeksi tehdä ulkoisesta datasta oikeanlaisia tulkintoja, oppia kyseisestä datasta ja soveltaa oppeja saavuttaakseen sille määritetyt tavoitteet. Tutkijoiden välillä on kuitenkin pitkälti yhteisymmärrys siitä, että tekoälyn rooli ei välttämättä ole ihmisten korvaamisessa, vaan heidän tukemisessaan aikaa vievissä ja haastavissa tehtävissä (Mikalef & Gupta, 2021).

Tekoälyssä ei ole kyse siitä, pystyvätkö koneet ajattelemaan. Tekoälyssä on kyse siitä, pystyvätkö koneet jäljittelemään ajatteluun kykenevien tekoja (Epstein ym., 2009). Ymmärtääksemme tekoälyn

käsitteen paremmin voimme tarkastella sanan englanninkielistä merkitystä. *Artificial* tarkoittaa keinotekoista, eli jotain ihmisen tekemää sen sijaan, että kyseinen asia ilmenisi luonnollisesti. *Intelligence* puolestaan tarkoittaa älykkyyttä, joka yleensä liitetään aivojen älyllisiin toimintoihin, kuten oppimiseen ja ymmärrykseen. Tekoäly tarkoittaa siis ihmisen kehittämää älykkyyttä. (Enholm ym., 2022.) Turingin testi on matemaatikko Alan Turingin 1950-luvulla kehittämä testi, jonka tarkoitus on selvittää voiko konetta kutsua älykkääksi. Kone läpäisee testin, mikäli koneen kanssa keskusteleva ihminen, joka ei etukäteen tiedä keskustelevansa koneen kanssa, ei keskustelun aikana tajua keskustelevansa koneen kanssa. Testin avulla voi siis selvittää onko tutkittavan koneen tapauksessa kyse tekoälystä. (Turing, 1950.) Vaikka testi on jo yli 70 vuotta vanha, sitä käytetään edelleen keinotekoisen älykkyyden määrittämisessä (Epstein ym., 2009).

Tekoäly ei itsessään ole uusi ilmiö. Siitä on puhuttu jo 1950-luvulla ja termi tekoäly vakiintui joitakin vuosia Turingin testin jälkeen (Enholm ym., 2022). Massadatan käsittelyssä hyödynnettävien teknologioiden kehitysaskelten myötä, kuten laskentatehon lisäännyttyä ja saatavuuden parannuttua, tekoäly on kokenut uuden nousun ja sen tutkimus on lisääntynyt merkittävästi. Tekoälyn uusimman aallon on mahdollistanut massadatan lisäksi tietojenkäsittelytieteen edistyminen, tärkeimpänä keinotekoiset neuroverkot (engl. artificial neural networks, ANN). (Duan ym., 2019.) Keinotekoiset neuroverkot ovat dataa käsitteleviä järjestelmiä, joiden rakenne jäljittelee ihmisten aivojen rakennetta (Kreutzer & Sirrenberg, 2020). ANN koostuu lukuisista toisiinsa kytköksissä olevista kerroksittain järjestellyistä prosessoreista, jotka yksittäisinä prosessoreina ovat hyvin yksinkertaisia. Koska ANN imitoi aivojen biologista rakennetta, ovat nämä järjestelmät kykeneviä toimimaan enemmän ihmisten ja eläinten kaltaisesti kuin perinteiset tietokoneet. (Uhrig, 1995.) ANN-teknologiaa hyödyntävien järjestelmien vahvuus on niiden soveltuvuus. Keinotekoiset neuroverkot kehittyvät itsenäisesti käsittelemänsä datan perusteella. ANN-teknologiaa hyödynnetään muun muassa kasvojentunnistuksessa. (Kreutzer & Sirrenberg, 2020.)

Keinotekoisten neuroverkkojen tutkimus aloitettiin jo 1940-luvulla (Haenlein & Kaplan, 2019), mutta kehitys laantui vuonna 1969, kun Minsky ja Papert (1988) totesivat tietokoneiden laskentatehon olevan riittämätön keinotekoisten neuroverkkojen toteuttamiseen. Rumelhart ym. (1986) esittivät neuroverkkojen kouluttamisen helpottamiseen ratkaisuksi vastavirta-algoritmin (engl. backpropagation). Rajallisen laskentatehon ja datan puutteen vuoksi neuroverkkojen kehitys ei kuitenkaan lähtenyt lentoon ennen 2000-lukua. (Aggarwal, 2023.) Keinotekoisten neuroverkkojen kehityksen eräs läpimurto tapahtui vuonna 2015, kun Googlen kehittämä ohjelmisto AlphaGo voitti Go-lautapelin maailmanmestarin. Lautapelin monimutkaisuuden vuoksi pitkään

uskottiin, että tätä ei olisi mahdollista saavuttaa tietokoneella. AlphaGo:n onnistumisen takana on menetelmä, joka tunnetaan syväoppimisena (engl. deep learning). Syväoppiminen mahdollistaa monet nykyaikaiset tekoälyn saavutukset, kuten kuvantunnistuksen ja itseohjautuvat ajoneuvot. (Haenlein & Kaplan, 2019.)

Janiesch ym. (2021) määrittelevät syväoppimisen koneoppimisen osa-alueena, joka perustuu keinotekoisiin neuroverkkoihin. Syväoppivilla järjestelmillä on enemmän tasoja keinotekoisessa neuroverkossaan kuin tavallisilla koneoppimisjärjestelmillä, mikä johtaa erityisesti valtavien datamäärien käsittelyssä tarkempiin tuloksiin. (Kreutzer & Sirrenberg, 2020.) Afiounin (2019) mukaan perinteisen koneoppimisen hyödyntämät keinotekoiset neuroverkot, joissa on vain yksi tai muutama kerros tuottavat tarkempia tuloksia kuin syväoppimista hyödyntävät järjestelmät sellaisissa tilanteissa, joissa saatavilla on vain pieni määrä yksiulotteista dataa. Syväoppimista hyödynnetään muun muassa käsin kirjoitetun tekstin tulkitsemisessa (Kreutzer & Sirrenberg, 2020).

Tietokoneet ovat jo pitkään olleet hyviä ratkaisemaan haastaviakin matemaattisia ongelmia nopeasti. Ihmisille yksinkertaiset tehtävät, kuten omenan ja appelsiinin erottaminen toisistaan, kuitenkin tuottivat niille suuria vaikeuksia. Tämä johtuu siitä, että sääntöjä, joilla erotus tehdään, on ollut haastavaa saattaa tarpeeksi selkeään muotoon, jotta ratkaisun voisi ohjelmoida koneeseen. (Afiouni, 2019.) Kovakoodattuun (eli suoraan lähdekoodiin syötettyyn, ei muualta haettuun tai ajon aikana syötettyyn) tietoon pohjautuvien järjestelmien kohtaamat haasteet yksinkertaisimmissakin älykkyyttä vaativissa tehtävissä ratkaistiin mahdollistamalla tekoälyjärjestelmille kyky hankkia tietoa datasta itse. Tätä järjestelmän itseopiskelua kutsutaan koneoppimiseksi ja tämä tapahtuu poimimalla datasta toistuvia kaavoja. (Goodfellow ym. 2016.) Koneoppimisessa järjestelmälle syötetään esimerkiksi kuvia autoista ja kerrotaan mikä niistä on urheiluauto. Datan pohjalta järjestelmä luo itse logiikan, jonka perusteella se jatkossa erottaa urheiluauton tavallisesta autosta. (Janiesch ym., 2021.) Koneoppimisalgoritmeilla koulutetaan keinotekoisten neuroverkkojen syviä kerroksia (Wamba-Taguimdje ym., 2020).

On olemassa erilaisia koneoppimisen muotoja, joiden ero ilmenee tavassa, jolla koneoppimisalgoritmeja koulutetaan. Yleensä koulutusmenetelmät jaetaan kolmeen luokkaan: valvottu oppiminen (engl. supervised learning), valvomaton oppiminen (engl. unsupervised learning) ja vahvistettu oppiminen (engl. reinforcement learning) (Li, 2017). Afiounin (2019) mukaan valvottu oppiminen tarkoittaa sitä, että järjestelmälle syötetään merkittyä dataa, josta järjestelmä havaitsee kaavamaisuuksia ja kehittää niiden perusteella itselleen säännöt, joiden perusteella se jatkossa ratkaisee vastaavat tehtävät. Esimerkiksi kiinteistöalan yrityksellä voisi olla

koneoppimisalgoritmi, joka ennustaa asuntojen hintoja ominaisuuksien perusteella. Järjestelmä koulutettaisiin syöttämällä sille asunnoista dataa, kuten neliömäärä sekä asunnon hinta. Jatkossa järjestelmä osaisi ennustaa asunnon hinnan pelkästään ominaisuuksien perusteella. Valvotussa oppimisessa käytetään yleensä kolmenlaisia tietoaineistoja (engl. datasets): koulutus-, vahvistus- ja testausaineistoja. Koulutusaineistojen pohjalta järjestelmä luo itselleen säännöt tehtävän ratkaisemiseksi. Vahvistusaineistoilla järjestelmän vastauksia verrataan oikeisiin vastauksiin ja parametreja säädetään sen mukaan. Testausaineistoilla kokeillaan järjestelmän ennusteiden tarkkuutta. Testausaineistojen on oltava erillisiä koulutus- ja vahvistusaineistoista, sillä järjestelmä onnistuu ennustuksissaan aina sen datan pohjalta, jolla se on koulutettu. (Choi ym., 2020.)

Lin (2017) mukaan valvomaton oppiminen tarkoittaa sitä, että järjestelmä kouluttaa itsensä datalla, johon ei ole merkitty oikeita vastauksia. LeCun ym. (2015) toteavat, että valvomattoman oppimisen tavoite on imitoida mahdollisimman läheisesti ihmisen oppimisprosessia, joka on myös pitkälti valvomaton. Valvomatonta oppimista hyödyntävät järjestelmät voivat tunnistaa datasta yhtäläisyyksiä, jotka ihmisiltä jäisivät esimerkiksi ennakkoluulojen vuoksi huomiotta. Tämän on todettu johtavan parempiin lopputuloksiin esimerkiksi asiakkaiden segmentoinnissa. (Afiouni, 2019.) Vahvistettu oppiminen eroaa kahdesta muusta oppimistavasta siten, että se ei perustu aiemman datan hyödyntämiseen, vaan järjestelmän kanssakäymiseen ulkoisten tekijöiden kanssa. Järjestelmälle syötetään ympäristöä rajaavia tekijöitä, sallitut toimenpiteet tavoitteen saavuttamiseksi sekä tavoitetulos (Janiesch ym., 2021). Vahvistettua oppimista voidaan kuvailla yritys ja erehdys -oppimiseksi, jossa järjestelmä tutkiskelee ympäristöä, kunnes löytää etsimänsä ratkaisun. (Li, 2017.) Afiouni (2019) mainitsee vahvistetun oppimisen haasteeksi sen, että optimaalisen ratkaisun löytäminen vaatii varsinkin kompleksisuuden lisääntyessä todella monia iteraatioita.

Afiounin (2019) mukaan syväoppiminen, koneoppiminen ja tekoäly ovat eri tason käsitteitä, joita usein kuitenkin käytetään toistensa synonyymeinä. Tekoäly on käsitteistä laajin, sillä se tarkoittaa yleisesti järjestelmiä, jotka ovat kykeneviä toteuttamaan perinteisesti älykkyyttä vaativia tehtäviä. Tekoälyyn sisältyvät joidenkin määritelmien mukaan myös kovakoodatut järjestelmät, jotka eivät välttämättä erottaisi appelsiinia omenasta, mutta kykenevät toteuttamaan muunlaisia tehtäviä tehokkaammin kuin ihminen. Koneoppiminen on puolestaan tekoälyn osa-alue, joka tarkoittaa järjestelmän kykyä opettaa itseään datasta ilman tarkoin määriteltyjä sääntöjä. (Afiouni, 2019.) Syväoppiminen on keinotekoisiin neuroverkkoihin perustuva koneoppimisen osa-alue (Janiesch ym., 2021). Tekoälyn eri osa-alueiden suhteutumisesta toisiinsa ei kuitenkaan vallitse yksimielisyyttä. Janiesch ym. (2021) asettavat koneoppimisen kattamaan alleen keinotekoiset

neuroverkot, joiden osa-alue syväoppiminen on. Choi ym. (2020) asettavat koneoppimisen alle syväoppimisen ja tämän alle keinotekoiset neuroverkot. Kreuzer ja Sirrenberg (2020) puolestaan asettavat keinotekoiset neuroverkot koneoppimisen yläpuolelle. Heidän näkemyksensä mukaista tekoälyn käsitteiden hierarkiaa havainnollistetaan kuvassa 1.

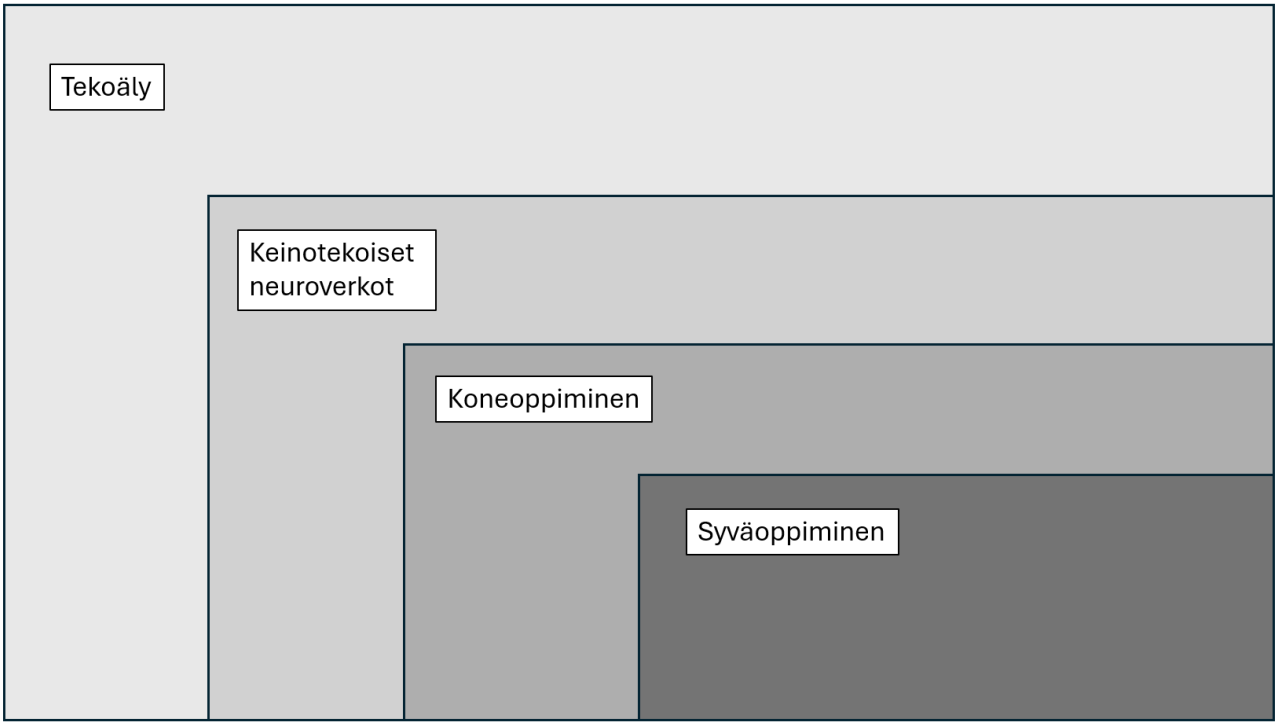

Kuva 1 Tekoälyn käsitteiden hierarkia, muokattu lähteestä (Kreutzer & Sirrenberg, 2020)

Samek ym. (2021) määrittelevät koneoppimisen tärkeimmäksi tavoitteeksi sellaisten järjestelmien kehittämisen, joilla voidaan automatisoida ihmisen tavallisesti tekemiä tehtäviä. Lisäksi he listaavat koneoppimisjärjestelmille tärkeitä ominaisuuksia, jotta niistä voi olla todellista hyötyä reaalimaailman sovelluksissa. Näitä ominaisuuksia ovat mm. turvallisuus- ja tietoturvanäkökulmat, kyky osoittaa käyttäjälle datasta tekemänsä havainnot, kuten korrelaatiot, sekä kyky arvioida omien ennusteidensa luotettavuutta. Wamba-Taguimdje ym. (2020) kertovat, että tekoälyn suurin hyöty ilmenee tehostamalla ja optimoimalla olemassa olevia prosesseja mm. automaatiolla. Lisäksi oleellista on tekoälyn vuorovaikutus ihmisen kanssa ja kyky tehdä havaintoja ja ennusteita.

2.3 Tekoäly lisätyssä analytiikassa

Lisätty analytiikka tarkoittaa edellä esiteltyjen tekoälyn kyvykkyyksien yhdistämistä analytiikkaan ja liiketoimintatiedon hallintaan (Alghamdi & Al-Baity, 2022). Andriole (2019) määrittelee analytiikan datasta löytyvien havaintojen tekemiseksi ja kommunikoimiseksi. Nämä ovat pitkälti

automatisoitavissa olevia toimintoja (Andriole, 2019). Tekoälyn ansiosta lisätty analytiikka sallii mahdollisuuden luoda kehittyneitä analytiikkamenetelmiä hyödyntäviä malleja sellaisillekin ihmisille, jotka eivät pääsääntöisesti työskentele analytiikan parissa. Tällaisia ihmisiä kutsutaan kansalaisdatatieteilijöiksi (engl. citizen data scientist). (Gartner, 2017.) Esimerkiksi Tableau-ohjelmistossa on työkalu, joka tuottaa automaattisesti havaintoja visualisoinneista tekoälyn avulla. Myös visualisoinnit voivat olla tekoälyn tuotoksia. Työkalu tekee havaintoja esimerkiksi trendeistä ja kertoo havainnoistaan luonnollisella kielellä. Myös datatieteilijät (engl. data scientist) hyötyvät lisätystä analytiikasta, sillä se tehostaa heidän työskentelyään erityisesti mekaanisissa tehtävissä. (Prat, 2019.)

Tekoälyä on hyödynnetty analytiikassa jo liiketoimintatiedon hallinnan toisessa sukupolvessa, muun muassa itsepalvelu-BI-ohjelmien suosittelemissa visualisoinneissa. NLG-sovellukset, joissa järjestelmä tuottaa havaintoja visualisoinneista, ovat puolestaan uusien tekoälyn kehitysaskelten ansiota ja ne kuuluvat kolmanteen BI-sukupolveen osana lisättyä analytiikkaa. IBM:n Watson Analytics on esimerkki työkalusta, jolta voi kysyä kysymyksiä datasta. (Prat, 2019.) Watson Analyticsin tilalla IBM tarjoaa nykyään Project Ripassoa, josta käytetään myös nimeä watsonx BI Assistant (IBM, 2024). Nämä työkalut hyödyntävät NLP- ja NLG-teknologioita käyttäjän kanssa keskustelemiseen (Prat, 2019).

Vaikka lopullista päätöksentekoa ja päätösten toimeenpanoa pidetään yleensä analytiikkatyökalujen tehtäväkentän ulkopuolisena tehtävänä, hyödyntämällä koneoppimismalleja operatiivista päätöksentekoa pystytään automatisoimaan yhä enemmän. (Prat, 2019.) Lisätyssä analytiikassa koneoppimisalgoritmeja käytetään muun muassa korrelaatioiden havaitsemisen automatisoimiseen. Esimerkiksi Microsoftin Power BI -ohjelmistossa on ominaisuus, joka etsii datasta automaattisesti korrelaatioita ja tulkitsee näitä hyödyntäen koneoppimista. Tämän kaltaisilla työkaluilla käyttäjät pääsevät käsiksi havaintoihin, jotka olisivat muuten saattaneet jäädä huomaamatta. (Alghamdi & Al-Baity, 2022.)

Koneoppimisen vahvuusalue on strukturoidun datan analysointi, kun taas luonnollisen kielen prosessointi sallii myös strukturoimattoman datan analysoinnin (Oesterreich ym., 2021). Molempien teknologioiden hyödyntäminen on siis tarpeen, jotta lisätyn analytiikan järjestelmistä voidaan saada suurin mahdollinen hyöty. Groverin ym. (2018) mukaan teknisten kyvykkyyksien lisäksi myös sosiaalisilla tekijöillä, kuten johdon osaamisella ja päätöksentekorakenteilla, on merkitystä arvon luomisessa lisätyllä analytiikalla.

3 Lisätyn analytiikan käyttö organisaation päätöksenteossa

3.1 Organisaation päätöksenteon luokittelu

Organisaation päätöksenteon voi jakaa kolmeen eri tasoon. Nämä tasot ovat strateginen, taktinen ja operatiivinen. Strateginen päätöksenteko koskee pitkän aikavälin päätöksiä, kuten uusille markkinoille laajentumista. Strategiset päätökset ovat vahvasti kytköksissä organisaation visioon, missioon ja pitkän aikavälin tavoitteisiin. Taktinen päätöksenteko puolestaan koskee keskipitkän aikavälin päätöksiä. Taktiset päätökset määräytyvät strategisten päätösten pohjalta ja niillä on tämän takia yleensä selkeämmät rajoitukset. Taktinen päätöksenteko koskee esimerkiksi toimintasuunnitelmia strategisten tavoitteiden saavuttamiseksi. Operatiivinen päätöksenteko koskee lyhyen aikavälin päätöksiä ja on paljon tarkempaa kuin taktinen tai strateginen päätöksenteko. (Edwards ym., 2000; Harrington & Ottenbacher, 2009.)

Duanin ym. (2019) mukaan Simon (1987) jaottelee päätöksenteon sen rakenteen perusteella strukturoituun, osittain strukturoituun ja strukturoimattomaan päätöksentekoon. Edwardsin ym. (2000) tutkimuksen mukaan tekoälyllä voidaan korvata päätöksentekijä strukturoiduissa ja osittain strukturoiduissa päätöksissä, mutta strukturoimattomissa päätöksissä sitä tulisi käyttää ennemmin päätöksentekijän tukemiseen. Strateginen päätöksenteko on strukturoimatonta, koska siihen liittyy valtava määrä eri toimintavaihtoehtoja. Lisäksi strateginen päätöksenteko vaatii tuekseen paljon tietoa organisaation ulkoisista lähteistä. Taktinen päätöksenteko on lähtökohtaisesti osittain strukturoitua, sillä se pohjautuu strategisiin päätöksiin, jotka luovat sille selkeät rajoitukset. Operatiivinen päätöksenteko on lähtökohtaisesti erittäin strukturoitua ja se perustuu lähes täysin organisaation sisäisen tiedon hyödyntämiseen. (Edwards ym., 2000.) Päätöksenteon rakenteellisuutta suhteessa päätöksentekotasoihin on havainnollistettu kuvassa 2. Kuvalla havainnollistetaan, että mitä ylemmäs mennään organisaation päätöksentekotasoilla, sitä vähemmän strukturoitua päätöksenteko on.

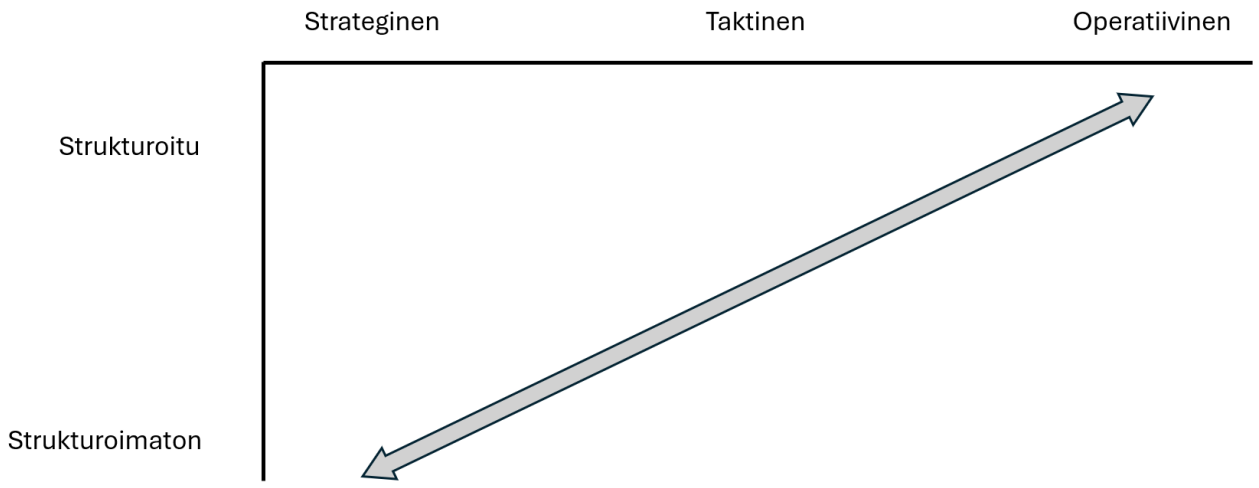

Kuva 2 Organisaation päätöksentekotasojen rakenteellisuus, muokattu lähteestä Edwards ym. (2000)

Päätöksenteon voi myös jakaa intuitiiviseen ja analyyttiseen päätöksentekoon. Intuitiivinen päätöksenteko tulee alitajunnasta, eikä se vaadi tiedonkeruuta tai loogista ja tiedostettua ajattelua perustakseen. Intuitiiviset päätökset tehdään pitkälti aiemman kokemuksen ja vaistojen perusteella. Analyyttinen päätöksenteko puolestaan perustuu vaihtoehtoisten ratkaisujen kehittämiseen, arviointiin ja vertailuun. Analyyttinen päätöksenteko vaatii tiedonkeruuta ja kerätyn tiedon analysointia loogisella ja tiedostetulla pohdinnalla. Intuitiivinen päätöksenteko lähestyy ongelmaa laajasta näkökulmasta, kun taas analyyttinen päätöksenteko keskittyy syvyyteen. Intuitiivinen ja analyyttinen päätöksenteko eivät ole toisiaan poissulkevia, vaan niitä käytetään usein rinnakkain moniulotteisten ongelmien ratkaisussa. (Jarrahi, 2018.)

Tekoäly on parempi tukemaan analyyttista päätöksentekoa kuin intuitiivista. Analyyttisessa päätöksenteossa tekoälytyökalut mahdollistavat valtavia datamääriä hyödyntävien laskelmien tuottamisen ja tulosten analysoinnin. Tekoäly on kuitenkin selvästi ihmistä heikompi tilanteissa, jotka vaativat maalaisjärkeä tai ovat arvaamattomia. Tekoäly onnistuu ihmistä paremmin korkean kompleksisuuden ongelmien ratkomisessa, mutta ihmiset päihittävät koneen epävarmuuden vallitessa intuitionsa ja mielikuvituksensa ansiosta. (Jarrahi, 2018.) Edwards ym. (2000) havaitsivat tutkimuksessaan, että tekoälyn hyödyntäminen päätöksentekijän korvaavassa roolissa tehostaa päätöksentekoa operationaalisella ja taktisella tasolla, mutta strategisella tasolla sen hyödyt ovat rajalliset. Lisäksi tutkimuksessa havaittiin, että päätöksentekijää tukevassa roolissa tekoäly paransi päätösten laatua kaikilla organisaation päätöksenteon tasoilla.

3.2 Lisätyn analytiikan käyttötavat ja -kohteet

3.2.1 Lisätty analytiikka päätöksentekorakenteissa

Tekoälyn hyödyntäminen päätöksenteossa on yksi tekoälyn tärkeimpiä sovelluskenttiä (Duan ym., 2019). Koneoppimisalgoritmien sallima automatisoitu ennusteiden ja tiedon poiminta suurista datamassoista on ollut yksi merkittävistä ajureista tekoälyn viimeaikaisessa kehityksessä. Monien alojen asiantuntijat hyödyntävät tekoälyä tärkeissäkin päätöksissä, kuten pankkien riskienhallintapäälliköt luottoriskin ennustamisessa. Tekoälyn hyödyntäminen päätöksenteossa tuo kuitenkin mukanaan myös haasteita erityisesti päätöksentekorakenteisiin. (Shrestha ym., 2019.) Tekoälyn onnistunut implementointi osaksi organisaation päätöksentekoa edellyttää tekoälyalgoritmien heikkouksien ja vahvuuksien ymmärtämistä (Kaplan & Haenlein, 2019). Shresthan ym. (2019) mukaan tekoälyä hyödyntävän päätöksenteon tuloksista vastaa loppukädessä aina tekoälyn hyödyntämisestä päättänyt tai sen sallinut johtaja.

Shrestha ym. (2019) esittävät kolmenlaisia organisaation päätöksentekorakenteita ja kuinka tekoälyn ja ihmisen voimavarat voidaan yhdistää niissä päätöksenteon optimoimiseksi. Ensimmäinen rakenne on päätöksenteon täysi valtuuttaminen tekoälylle. Toinen rakenne on ihmisen ja tekoälyn peräkkäinen hyödyntäminen päätöksentekoprosessissa joko siten, että ensin vastuu on tekoälyllä, mutta lopullisen päätöksen tekee ihminen, tai päinvastoin. Kolmas rakenne on ihmisen ja tekoälyn yhteen koottu päätöksenteko, jossa kumpikin tekee ratkaisuja vahvuuksiensa perusteella ja lopulta näiden pohjalta tehdään päätös. Rakenteita vertaillaan muun muassa päätöksentekonopeuden, tulosten toistettavuuden, vaihtoehtojen lukumäärän ja päätöksentekoprosessin läpinäkyvyyden näkökulmista.

Järjestelmät, joissa tekoälyalgoritmit toteuttavat päätöksenteon ilman ihmisen osallistumista, toimivat parhaiten tilanteissa, joissa vaihtoehtoja on paljon ja päätökset pitää tehdä nopeasti. Esimerkki tällaisesta järjestelmästä ovat dynaamisen hinnoittelun järjestelmät. Kun päätöksenteko on lähes välitöntä ja päätökset perustuvat miljoonien datapisteiden arviointiin, ihmisen osallistuminen hidastaa päätöksentekoprosessia ja todennäköisesti heikentää myös päätösten laatua. Ihmisellä on kuitenkin aina vastuu sellaistenkin järjestelmien päätöksistä, joissa päätöksenteon suorittaa kokonaan tekoälyalgoritmi. Esimerkiksi se, mitä tekoälyyn perustuva suosittelujärjestelmä (engl. recommender system) tuo käyttäjän etusivulle sosiaalisessa mediassa, on kyseisen yhtiön vastuulla, eikä syytä voi vierittää tekoälyn harteille. (Shrestha ym., 2019.)

Hybridirakenteisissa järjestelmissä, joissa ihmistä ja tekoälyä hyödynnetään päätöksenteossa peräkkäin, ensimmäisen tulos toimii jälkimmäisen syötteenä (Langley ym., 1995). Shresthan ym. (2019) mukaan tällainen päätöksentekorakenne sallii ihmisen ja tekoälyn vahvuuksien hyödyntämisen, mutta voi kuitenkin myös vahvistaa kummankin heikkouksia. Järjestelmät, joissa ensin hyödynnetään tekoälyä alkuperäisten vaihtoehtojen suodattamiseen ja tämän jälkeen jäljellä olevat vaihtoehdot annetaan ihmiselle, toimivat hyvin tilanteissa, joissa vaihtoehtoja on valtavasti, mutta halutaan kuitenkin, että ihminen tekee lopullisen päätöksen. Tekoälyn täyteen autonomiaan verrattuna hybridimalli on parempi päätöksentekoprosessin läpinäkyvyyden kannalta, mutta häviää nopeudessa ja tulosten toistettavuudessa. Tällainen järjestelmä soveltuu muun muassa rekrytointiin. (Shrestha ym., 2019.)

Hybridirakenteinen järjestelmä voi myös olla sellainen, jossa ihminen valikoi eri vaihtoehdoista joukon, jonka esittää tekoälyalgoritmille. Algoritmi tekee lopullisen päätöksen valittavasta vaihtoehdosta. Tällainen rakenne on optimaalinen silloin, kun ihmisen on helppo valita tietty joukko vaihtoehdoista, mutta näiden vaihtoehtojen välillä parhaan valinta vaatii suurten datamäärien prosessointia. Ihmisen tehdessä alustavan karsinnan vaihtoehtoja ei voi olla valtavaa määrää. Tällainenkin hybridimalli häviää tekoälyn autonomialle nopeudessa ja toistettavuudessa, mutta parantaa päätöksentekoprosessin läpinäkyvyyttä, etenkin jos ihminen osallistuu vielä tekoälyn päätöksen jälkeen ratkaisun arviointiin. Tällaista rakennetta käytetään muun muassa terveydenhuollossa. (Shrestha ym., 2019.)

Kolmannessa päätöksentekorakenteessa eri päätöksenteon vaiheet, eli pienemmät päätökset, allokoidaan ihmiselle tai tekoälylle näiden vahvuuksien mukaan. Päätöksistä kootaan yhteen lopullinen päätös esimerkiksi siten, että se vaihtoehto, johon suurin osa päätöksistä johtaa, valitaan. Esimerkiksi rekrytoinnissa ihminen voi tällöin keskittyä arvioimaan hakijan vaikeammin määriteltäviä ominaisuuksia, kuten soveltuvuutta organisaation kulttuuriin. Toisin kuin hybridirakenteisissa järjestelmissä, tällaisessa järjestelmässä ihminen ja tekoäly tekevät päätöksensä toisistaan riippumattomina. Tällöin riski siitä, että algoritmi toistaa ja vahvistaa ihmisen tekemiä päätöksentekovirheitä pienenee. Tällaisessakin järjestelmässä päätöksentekoprosessin läpinäkyvyys on heikko. (Shrestha ym., 2019.)

3.2.2 Lisätty analytiikka liiketoiminta-analytiikkasyklin eri vaiheissa

Pratin (2019) aiemman kirjallisuuden pohjalta rakentaman liiketoiminta-analytiikkasyklin (engl. business analytics cycle) havainnekuvion (kuva 3) ensimmäinen vaihe on liiketoimintaongelman tunnistaminen. Tässä vaiheessa myös analysoidaan liiketoimintaongelman tuottamia

mahdollisuuksia. Seuraava vaihe on datan valmistelu, jossa profiloidaan data, eli arvioidaan sen laatu. Lisäksi tässä vaiheessa muunnetaan data haluttuun muotoon seuraavaa vaihetta, eli datan analysointia varten. Analysointivaiheessa etsitään datasta havaintoja ja mallinnetaan dataa. Seuraavaksi mallit otetaan käyttöön liiketoimintaprosesseissa, mitä seuraa päätöksenteko ja sen perusteella tehtävien toimenpiteiden toteuttaminen. Viimeisessä vaiheessa seurataan toimenpiteiden ja mallien vaikutuksia. Lisätty analytiikka mahdollistaa automaation liiketoiminta-analytiikkasyklin jokaisessa vaiheessa. Tämä on erityisen merkityksellistä, kun halutaan hyödyntää massadataa päätöksenteossa. (Prat, 2019.)

Kuva 3 Liiketoiminta-analytiikkasykli, muokattu lähteestä (Prat, 2019)

Taulukossa 1 on esitetty Pratin (2019) näkemys tekoälyn hyödyntämisestä liiketoiminta-analytiikkasyklin eri vaiheissa. Ensimmäisessä vaiheessa, liiketoimintaongelman tunnistamisessa ja

sen tuomien mahdollisuuksien analysoinnissa, tarvitaan lähtökohtaisesti ihmistä, siispä siihen ei ole varsinaista tekoälysovellusta. Ensimmäisessä vaiheessa voidaan kuitenkin hyödyntää dataa aiemmista sykleistä tekoälysovellusten avulla. Vaikka strategisessa päätöksenteossa, kuten liiketoimintaan liittyvien ongelmien ja mahdollisuuksien tunnistamisessa, automaatio ei ole vielä mahdollista, sen vaikutukset analytiikkasyklin muissa vaiheissa vaikuttavat myös strategiseen päätöksentekoon. Lisätyn analytiikan työkaluilla automaattisesti tuotetut havainnot voivat olla merkittävä apu liiketoimintaongelmien tunnistamisessa tulevaisuudessa. (Prat, 2019.)

Toisessa vaiheessa, eli datan valmistelussa, tekoälysovellukset voivat määritellä datan laadun automaattisesti, sekä tehdä ehdotuksia sen järjestelyyn ja siivoamiseen liittyen. Pratin (2019) mukaan datan valmistelu on yleensä analytiikkaprosessin työläin vaihe. Datan valmistelun automatisointiin on jo olemassa sovelluksia, joilla voidaan automatisoida datan profiloinnin (engl. data profiling) ja muuntamisen (engl. data transformation) toistuvia vaiheita. Esimerkiksi datan profiloinnin automaatiossa järjestelmä havaitsee tyhjiä arvoja ja automatisoitu datan muuntaminen tekee näille tyhjille arvoille ennalta määriteltyjä toimenpiteitä. (Prat, 2019.) Näiden vaiheiden automatisointi vapauttaa datatieteilijät keskittymään analytiikkaprosessin monimutkaisempiin vaiheisiin ja tehostaa täten koko prosessia. Esimerkiksi IBM:n InfoSphere Information Server hyödyntää koneoppimista datan valmistelun tehostamiseen. (Alghamdi & Al-Baity, 2022.)

Kolmannessa vaiheessa tekoälysovellukset auttavat datan analysoinnissa mm. antamalla visualisointiehdotuksia ja löytämällä korrelaatioita datasta (Alghamdi & Al-Baity, 2022). Lisäksi tekoäly pystyy tulkitsemaan luonnollista kieltä ja tuottamaan luonnollisella kielellä havaintoja datasta. Tämä helpottaa kansalaisdatatieteilijöiden työskentelyä datan parissa huomattavasti. Mallien käyttöönottovaiheessa tekoälyä hyödyntämällä voidaan sujuvoittaa mallien tuottamisen ja käyttöönoton välistä siirtymää, joka on perinteisesti ollut jäykkä. Tekoälyllä voidaan automatisoida sekä siirtymä että mallien toiminnan seuranta niiden optimoimiseksi, esimerkiksi mallien jatkuva kouluttaminen tuoreella datalla. (Prat, 2019.) Alghamdin ja Al-Baityn (2022) mukaan lisätyllä analytiikalla voidaan pienentää vinoumien riskiä ja lisätä tehokkuutta mallien kehityksessä ja valinnassa.

Viides ja kuudes vaihe, eli päätöksenteko ja päätöksiin pohjautuvat toimenpiteet, ovat joissain tilanteissa automatisoitavissa (Prat, 2019). Alghamdin ja Al-Baityn (2022) mukaan teknologiat eivät ole vielä tarpeeksi kehittyneitä eliminoimaan ihmisen osallistumista näihin vaiheisiin. Koneoppimismalleja hyödyntämällä voidaan esimerkiksi automatisoida päätöksiä seuraavat toimenpiteet ja päätöksissä voidaan käyttää tukena NLG-järjestelmien tuottamia ehdotuksia.

Erityisesti massadatan takia operationaalista päätöksentekoa automatisoidaan yhä enemmän. Liiketoiminta-analytiikkasyklin viimeisessä seurantavaiheessa tekoälyä voidaan hyödyntää mallien muokkaamisessa, esimerkiksi kouluttamalla malleja automaattisesti syöttämällä sinne lisää dataa. (Prat, 2019.)

Taulukko 1 Tekoälyn hyödyntäminen liiketoiminta-analytiikkasyklin eri vaiheissa, muokattu lähteestä Prat (2019).

Liiketoiminta-analytiikkasyklin vaihe	**Tekoälyn soveltaminen vaiheessa**
1. Liiketoimintaongelman tunnistaminen	- Voidaan hyödyntää dataa aiemmista sykleistä tekoälyn avulla
2. Datan valmistelu	- Datan laadun automaattinen määrittely - Ehdotukset datan järjestelyyn, puhdistukseen ym.
3. Datan analysointi	- Visualisointiehdotuksia ja parannuksia, löydösten tekemisessä opastaminen, luonnollisen kielen tulkitseminen ja tuottaminen - Mallinnuksen ominaisuuksien rakentaminen
4. Mallien käyttöönotto	- Mallien käyttöönotto ja suora implementointi järjestelmiin
5. Päätöksenteko	- Automatisointi mahdollista tietynlaisissa tilanteissa, muutoin tukee ihmistä päätöksenteossa
6. Toiminta	- Automatisointi mahdollista, tukee ihmisen toimintaa tehostamalla sitä
7. Seuranta	- Mallien muokkaaminen seurannassa ilmenneiden havaintojen pohjalta

Voidaan todeta, että lisätyn analytiikan ratkaisuilla voidaan automatisoida suuri osa liiketoiminta-analytiikkasyklin vaiheista. Ihmistä tarvitaan kuitenkin edelleen erityisesti syklin ensimmäisessä vaiheessa, liiketoimintaongelman tunnistamisessa, sekä viidennessä vaiheessa eli päätöksenteossa. (Prat, 2019.) Teknologian kehittyessä lisätyn analytiikan merkitys liiketoiminta-analytiikkasyklin alku- ja loppuvaiheissa, kuten ongelmien tunnistamisessa ja päätöksenteossa, tulee kasvamaan (Oesterreich ym., 2021). Näissä vaiheissa tekoäly voi kuitenkin jo nyt tukea ja tehostaa ihmisen työskentelyä. Merkittävin vaikutus tekoälyllä liiketoiminta-analytiikkasyklissä on toistuvien ja työläiden vaiheiden automatisointi, joka vapauttaa ihmisille aikaa keskittyä prosessin niihin vaiheisiin, jotka tuottavat enemmän arvoa. (Prat, 2019.)

3.3 Lisätyn analytiikan käytön onnistumisen edellytykset

3.3.1 Arvon luominen lisätyllä analytiikalla

Liiketoimintahyötyjen saamiseksi analytiikan avulla on esitetty lukuisia malleja. Esimerkiksi Davenport ym. (2010) listaavat DELTA-mallissaan oleelliseksi laadukkaan datan, koko yrityksen laajuisen orientaation analytiikkaa kohtaan, analyyttisen johtamisen eri tasoilla, strategiaa tukevat tavoitteet ja analyyttiset ihmiset. Tämän ja muiden mallien pohjalta Seddon ym. (2017) kehittivät mallin, joka huomioi myös psykologisten tekijöiden, kuten ihmisen ongelmanratkaisu- ja päätöksentekoprosessien, vaikutuksen analytiikan hyödyntämiseen liiketoiminta-arvon kasvattamiseksi. Malli on prosessimalli, joka kuvaa analytiikan käytön prosessin liiketoimintahyötyjen saavuttamiseksi. Prosessi pohjautuu ihmisen päätöksentekoprosessiin ja sen tärkeimmät vaiheet arvon tuottamisen kannalta ovat havainnot, päätöksenteko ja toimenpiteet. Analytiikan käyttö tuottaa havaintoja, jotka tukevat päätöksentekoa. Mikäli havaintojen pohjalta tehdyt päätökset johtavat arvoa tuottaviin toimenpiteisiin, on analytiikka johtanut liiketoiminta-arvon kasvattamiseen. (Seddon ym., 2017.)

Suosittelujärjestelmät ovat aiemmin keskittyneet merkittäviin investointipäätöksiin, mutta nykyään niiden painopiste on suuremmassa volyymissa ja pienemmissä päätöksissä. Esimerkiksi Netflix ja Amazon käyttävät suosittelujärjestelmiä operatiivisen päätöksenteon tehostamiseen. (Duan ym., 2019.) Seddon ym. (2017) pitävät havaintojen tekemistä ja erityisesti päätöksentekoa perustavanlaatuisen inhimillisinä toimintoina. Päätöksenteon inhimillisen luonteen takia analytiikan avulla tehdyt havainnot eivät välttämättä johda arvoa luoviin päätöksiin. Analytiikasta ja sen tuottamista havainnoista ei ole hyötyä, elleivät ne johda konkreettisiin arvoa luoviin toimenpiteisiin. (Seddon ym., 2017.) Havainnot, päätöksenteko ja toimenpiteet ovat Pratin (2019) mukaan liiketoiminta-analytiikkasyklin vaiheet, jotka useimmiten eivät ole automatisoitavissa. Ihmisen työpanosta tarvitaan siis edelleen liiketoiminta-analytiikkasyklin eniten arvoa tuottavissa vaiheissa.

Davenport ja Patil (2012) toteavat johtajille suunnatussa artikkelissaan, että lukuisat eri organisaation työntekijät voivat hyödyntää analytiikkaa arvon luomiseksi, myös sellaiset, jotka eivät perinteisesti työskentele datan tai analytiikan parissa. Seddon ym. (2017) väittävät, että kaikkien eri organisaation työntekijöiden tekemät havainnot voivat olla hyödyllisiä ja arvoa tuottavia. Tästä syystä heidän mukaansa useammilla ihmisillä organisaatiossa tulisi olla pääsy analytiikkatyökaluihin. Lisäksi he painottavat prosessin jatkuvan toistamisen merkitystä sanoen, että prosessin toistaminen eri ihmisten toimesta on analytiikasta saatavien hyötyjen

perustavanlaatuinen ajuri. Lisätty analytiikka edesauttaa tätä tekemällä analytiikasta saavutettavampaa kansalaisdatatieteilijöille.

Alghamdin ja Al-Baityn (2022) mukaan Grigorescu ym. (2020) havaitsivat romanialaisten yhtiöiden tutkimuksessaan, että lisätty analytiikka mm. paransi päätöksentekoa, laski kustannuksia, säästi aikaa ja täsmensi raportointia. Tutkimuksessa haastatellut ylimmän johdon edustajat sanoivat, että lisätyn analytiikan ratkaisujen käyttöönotto on tärkeää kilpailuedun saavuttamiseksi. Alghamdi ja Al-Baity (2022) viittaavat aiempaan kirjallisuuteen toteamalla, että lisätty analytiikka nopeuttaa johdon päätöksentekoa ja parantaa tehtyjen päätösten laatua sekä pystyy myös ratkaisemaan monimutkaisia liiketoimintaongelmia.

Alghamdi ja Al-Baity (2022) havaitsivat tekemässään kokeessa, että lisätty analytiikka helpotti analysointiprosessia, erityisesti automaattisten havaintojen avulla. Kaikki työkalujen tuottamat havainnot eivät kuitenkaan olleet oleellisia liiketoimintaongelmaan nähden, ja analyytikoiden taidot tulivat yhä tarpeeseen havaintojen tulkitsemisessa. Ahituv ym. (1998) havaitsivat tutkimuksessaan, että rajallinen aika päätöksentekotilanteessa heikensi päätösten laatua lähes aina, kun päätöksentekijä oli ihminen. Smithin ym. (1982) mukaan päätöksentekijät ovat vähemmän luottavaisia aikapaineen alla tekemiinsä ratkaisuihin. Koneoppimisjärjestelmät ovat kykeneviä tekemään päätöksiä lähes välittömästi, mikä tekee niistä tehokkaampia nopeassa päätöksenteossa, kuten valuuttakaupassa (Shrestha ym., 2019).

Lisätyn analytiikan hyödyntäminen organisaation päätöksenteossa tekee analytiikasta helppokäyttöisempää ja saavutettavampaa, mikä edistää oikea-aikaista dataan perustuvaa päätöksentekoa. Lisätyn analytiikan ansiosta datatieteilijät voivat keskittyä vaativampiin tehtäviin, jotka eivät ole automatisoitavissa. AA-ratkaisut tehostavat muidenkin kuin datatieteilijöiden työskentelyä, sillä muut työntekijät, jotka tavallisesti joutuvat kysymään asioita datatieteilijöiltä, voivat nyt saada nopeammin vastauksen kysymyksiinsä vaivaamatta datatieteilijää. (Alghamdi & Al-Baity, 2022.)

3.3.2 Rajoitukset ja riskit

Lisätyn analytiikan lukuisista liiketoimintahyödyistä huolimatta se ei ole vailla ongelmia. Pratin (2019) mukaan yksi merkittävistä lisättyä analytiikkaa rajoittavista tekijöistä on sen riippuvuus sille syötetystä datasta, joka saattaa sisältää vinoumia. Alghamdin ja Al-Baityn (2022) mukaan päätöksentekoprosesseista on tullut entistä enemmän dataan perustuvia, kun niitä on automatisoitu koneoppimisen ja luonnollisen kielen käsittelyn avulla. Tämän takia datan valikoinnissa ja

valmistelussa ihmisen osallistuminen on edelleen oleellista. Toisaalta vinoumien riski datan manuaalisessa käsittelyssä ja analysoinnissa lisääntyy datan määrän kasvaessa (Gartner, 2017), siispä näissä vaiheissa ihmisen osallistuminen saattaa lisätä vinoumien riskiä.

Vaikka tekoäly voi olla hyödyllinen liiketoimintaongelmien ratkaisemisessa, liiketoimintaongelman tunnistaminen vaatii edelleen ihmisen. Päätöksenteon ja sitä seuraavien toimenpiteiden automatisointi kokonaan on tällä hetkellä mahdollista vain operatiivisissa päätöksissä. Lisätyn analytiikan hyödyntämistä taktisessa ja strategisessa päätöksenteossa rajoittaa pitkälti se, että useimmiten päätöksenteon kohteena olevat ongelmat ja niiden ratkaisut eivät ole yksiselitteisiä. Usein päätöksiin vaikuttaa datan lisäksi myös esimerkiksi moraali ja empatia. (Prat, 2019.) Cremerin ja Vandekerckhoven (2017) mukaan moraalin ja etiikan merkitys liiketoiminnassa on kasvanut yhä suuremmaksi. Woiceshynin (2011) mukaan liiketoiminnassa tehdyillä päätöksillä on laajamittaisia vaikutuksia esimerkiksi ympäristön tilan heikkenemiseen. Pratin (2019) mukaan tekoäly ei ainakaan vielä pysty imitoimaan moraalista tai empaattista ajattelua. Tämä pitää huomioida tekoälylle asetettavissa tavoitteissa.

Liiketoimintahyötyjen maksimoiminen on usein ristiriidassa moraalin kanssa. Suosittelujärjestelmät, joiden tavoitteeksi on asetettu ainoastaan käyttäjien osallistuminen ja tätä kautta tuottojen maksimoiminen, saattavat altistaa käyttäjiä haitalliselle sisällölle, kuten harhaanjohtavalle ja radikalisoivalle retoriikalle. Muun muassa algoritmin tavoitteiden määrittelyssä ja datan keruumenetelmien valinnassa voidaan tehdä eettisiä valintoja algoritmin suositusten aiheuttamien haittojen minimoimiseksi. (Shrestha ym., 2019.)

Koneoppimisalgoritmit voivat sisäistää ihmisten ennakkoasenteita esimerkiksi sukupuolta tai rotua kohtaan datasta, jolla algoritmit koulutetaan. Shresthan ym. (2019) mukaan Caliskan ym. (2017) havaitsivat tutkimuksessaan, että Google Kääntäjä, joka hyödyntää koneoppimista luonnollisen kielen tuottamisessa, kääntää sukupuolineutraalit pronominit sukupuolittuneisiin pronomineihin yhteiskunnallisten stereotypioiden perusteella. Esimerkiksi turkinkieliset lauseet ”O bir doktor. O bir hemşire.” kääntyivät englanniksi ”He is a doctor. She is a nurse”. Google Kääntäjään on sittemmin kehitetty ominaisuus, joka antaa sukupuolineutraaleja pronomineja käännettäessä käännöksen kaikilla sukupuolipronomineilla kielissä, joissa on sukupuolittuneet pronominit.

Koneoppimista hyödynnetään muun muassa rekrytoinnissa. Vaikka useimmiten tekoälyä ei hyödynnetä rekrytoinnissa autonomisesti, vaan lopulliset päätökset tekee ihminen, tekoälyn ennakkoluulot esimerkiksi naisten etunimiä tai ulkomaalaisia sukunimiä kohtaan voivat saada järjestelmän karsimaan näitä hakijoita pois ennen kuin ihminen osallistuu hakemusten arviointiin

(Caliskan ym., 2017). Esimerkiksi Amazonin tekoälyä hyödyntävä rekrytointityökalu osoittautui syrjiväksi naishakijoita kohtaan. Rekrytointijärjestelmät koulutetaan datalla aiemmista rekrytointipäätöksistä, jolloin ihmisten ennakkoluulot periytyvät helposti järjestelmälle. Ilman asiaan puuttumista koneoppimisjärjestelmät voivat vahvistaa kulttuurisia stereotypioita entisestään. (Shrestha ym., 2019.)

Jarrahin (2018) mukaan ihmisen ja tekoälyn yhteistyötä tarvitaan todennäköisesti suurimmassa osassa kompleksia päätöksentekoa. Tämä johtuu siitä, että sellaisiinkin päätöksiin, joissa tekoäly on tehokkaampi, vaikuttavat epävarmuustekijät. Ihminen on huomattavasti tekoälyä tehokkaampi epävarmuuden vallitessa muun muassa luovuutensa ja mielikuvituksensa ansiosta. Lisäksi ihminen on tehokkaampi käsittelemään asioita holistisesti. Jarrahin (2018) mukaan Davenport (2018) sanoi laajojen strategisten ongelmien vaativan kokonaisvaltaisen lähestymistavan, johon sisältyy muitakin tekijöitä kuin dataa. Jarrahi (2018) pitää mahdollisuutta yksinomaan tekoälyä hyödyntävästä organisaation päätöksentekojärjestelmästä pienenä.

Teknisten rajoitteiden lisäksi lisätyn analytiikan käyttöönotto aiheuttaa sosiaalisia haasteita liittyen ihmisiin ja vuorovaikutukseen, kuten muutoksia analytiikkasyklin roolituksessa. Liiketoiminta-analytiikkasyklin eri vaiheiden automatisoituessa ihmisten työvoimaa vapautuu keskittymään vaativampiin tehtäviin. Tämä voi kuitenkin aiheuttaa myös haasteita, sillä työntekijöiden roolien muokkaaminen ja uusien työtehtävien löytäminen ei ole aina helppoa. (Prat, 2019.) Oesterreichin ym. (2021) mukaan lisätty analytiikka nähdään ratkaisuna datatieteilijöiden saatavuuspulaan. Analytiikan valvonta, kuten datan laadun ja määräysten noudattamisen varmistaminen, muuttuu kuitenkin entistä haastavammaksi, kun datan valikointi ja valmistelu tulee saavutettavammaksi (Prat, 2019).

Automaatiota integroidaan osaksi päätöksentekoa yhä enemmän koneoppimisen kehittymisen myötä. Abdulin ym. (2018) mukaan ihmisten ymmärrystä näitä järjestelmiä kohtaan tulee lisätä, etenkin sitä, miten järjestelmät vaikuttavat ihmisen päätöksentekoon, jotta järjestelmiin voidaan luottaa. Shneidermanin ym. (2016) mukaan järjestelmien täyden autonomian sijaan ihmisten pysyminen kontrollissa automaation lisääntyessä on tärkeää. Tekoälyalgoritmien tulisi tehdä päätöksistä ja niiden taustalla olevista prosesseista läpinäkyvämpiä perustelemalla tuloksensa ja miten niihin on päädytty, jotta käyttäjän oma vastuu selkeytyisi. Tämä pienentää vinoumien riskiä. Käyttäjillä on parempi kontrolli algoritmien toiminnasta, jos päätöksentekoa tukeva järjestelmä paljastaa päätösten taustalla toimivat laskennalliset prosessit. (Abdul ym., 2018; Shneiderman ym., 2016.)

4 Yhteenveto ja johtopäätökset

Tutkielmassa tarkasteltiin lisättyä analytiikkaa ja sen hyödyntämistä osana organisaation päätöksentekoa. Tutkielma toteutettiin kirjallisuuskatsauksena, jonka avulla selvitettiin, miten lisätty analytiikka eroaa liiketoimintatiedon hallinnasta ja miten lisättyä analytiikkaa voidaan hyödyntää organisaation päätöksenteossa. Lisättyä analytiikkaa on tutkittu kirjallisuudessa jonkin verran, mutta sen tutkimus osana organisaation päätöksentekoa on vähäistä, erityisesti suomeksi. Tutkielma täyttää osittain tätä aukkoa alan tutkimuksessa. Seuraavaksi käydään läpi kirjallisuuskatsauksen avulla tehdyt johtopäätökset sekä potentiaaliset jatkotutkimusmahdollisuudet.

Tutkielmassa esiteltiin aluksi liiketoimintatiedon hallinta ja tekoäly sekä niiden yhdistämisestä muodostuva lisätty analytiikka. Seuraavaksi esiteltiin organisaation päätöksenteon luokittelua ja päätöksentekorakenteita sekä sitä, miten lisätty analytiikka yhdistyy näihin rakenteisiin. Tämän jälkeen esiteltiin liiketoiminta-analytiikkasykli ja lisätyn analytiikan hyödyntäminen syklin eri vaiheissa. Lopuksi käsiteltiin lisätyn analytiikan hyödyntämisen onnistumisen edellytyksiä mahdollisuuksien ja rajoitteiden kautta. Seuraavaksi käydään läpi johtopäätökset tutkimuskysymysten avulla.

Ensimmäinen tutkimuskysymys oli ”Mitä on lisätty analytiikka ja miten se eroaa perinteisestä liiketoimintatiedon hallinnasta?”. Tätä lähdettiin tarkastelemaan avaamalla ensin käsitteet liiketoimintatiedon hallinta ja tekoäly. Liiketoimintatiedon hallinta tarkoittaa liiketoiminnan kannalta oleellisen tiedon poimimista raakadatasta ja käsittelyä muotoon, jossa sitä voi hyödyntää esimerkiksi päätöksenteossa. Tekoäly on kattotermi, jolla ei ole yksiselitteistä merkitystä. Tutkielmassa käsiteltiin tekoälyn eri sovelluksia, kuten koneoppimista, neuroverkkoja ja luonnollisen kielen käsittelyä. Tekoälyn voi kuitenkin yleistää tarkoittamaan järjestelmiä, joilla on kyky mallintaa ihmisille ominaista älyllistä toimintaa.

Lisätty analytiikka tarkoittaa tekoälyn kyvykkyyksien yhdistämistä liiketoimintatiedon hallintaan. Kun lisätyn analytiikan muodostavat osat oli esitelty, käsiteltiin sitä, miten lisätty analytiikka hyödyntää edellä mainittuja kyvykkyyksiä. Tutkielma osoitti, että koneoppimisen ja luonnollisen kielen käsittelyn hyödyntäminen datan analysoinnissa tuottaa kattavimmat tulokset, sillä niiden vahvuusalueet ovat erilaisen datan käsittelyssä. Koneoppimisen vahvuus on strukturoidun datan käsittely, kun taas NLP-teknologiat voivat tulkita myös strukturoimatonta dataa. Lisätyn analytiikan eroja perinteiseen liiketoimintatiedon hallintaan on esitetty taulukossa 2.

Taulukko 2 Lisätyn analytiikan ja perinteisen liiketoimintatiedon hallinnan eroja

Liiketoimintatiedon hallinta	**Lisätty analytiikka**
Datan valmistelu ja analysointi manuaalisesti	Tekoälyä hyödyntävät työkalut valmistelevat ja analysoivat datan automaattisesti
Pääasiassa datan parissa työskenteleville	Kansalaisdatatieteilijät voivat hyödyntää helppokäyttöisiä työkaluja
Ei riittävä massadatan käsittelyyn	Kykenee käsittelemään tehokkaasti massadataa
Keskittyy pääasiassa strukturoituun dataan	Hyödyntää strukturoitua, osittain strukturoitua ja strukturoimatonta dataa
Päätöksenteon suorittaa ihminen	Tekoäly automatisoi tai tukee ihmistä päätöksenteossa
Aikaa vievä prosessi	Automaatio nopeuttaa prosessia huomattavasti

Perinteisellä BI:llä ja AA:lla on liiketoiminta-analytiikkasyklin työläimpien vaiheiden, datan valmistelun ja analysoinnin, käsittelyssä merkittävä ero tehokkuudessa. Tekoälyn ansiosta lisätyllä analytiikalla datan valmistelu ja analysointi tapahtuu automaattisesti vapauttaen resursseja liiketoiminta-analytiikkasyklin enemmän arvoa tuottaviin vaiheisiin. Lisätyn analytiikan työkalut ovat myös helppokäyttöisempiä sallien kansalaisdatatieteilijöille mahdollisuuden hyödyntää edistyneitä analytiikkatyökaluja ja tehden täten analytiikasta saavutettavampaa.

Kenties tärkein syy lisätyn analytiikan merkityksen kasvuun on massadata. Lisätty analytiikka on huomattavasti perinteisiä BI-ratkaisuja kyvykkäämpi massadatan käsittelyssä. Massadatan onnistunut hyödyntäminen tuo organisaatiolle kilpailuetua. Datan määrän ja kompleksisuuden lisääntyessä strukturoimattoman datan määrä on myös lisääntynyt. Perinteiset BI-järjestelmät keskittyvät pääosin strukturoituun dataan, kun taas lisätyn analytiikan työkaluilla myös strukturoimatonta ja osittain strukturoitua dataa voidaan käsitellä NLP-teknologioiden hyödyntämisen ansiosta.

Lisätty analytiikka tuo monenlaisia hyötyjä päätöksentekoon. Operatiivisessa päätöksenteossa päätökset ja niitä seuraavat toimenpiteet voidaan joissain tapauksissa automatisoida kokonaan. Sellaisissa tapauksissa, joissa päätöksentekoa ei vielä voida automatisoida, tekoäly tukee ihmistä päätöksenteossa nopeuttaen prosessia ja parantaen laatua. Automatisaatio nopeuttaa liiketoimintatiedon hallinnan prosesseja huomattavasti, ja lisätty analytiikka säästääkin paljon aikaa ja henkilöstöresursseja.

Tutkielman toinen tutkimuskysymys oli ”Miten lisätyn analytiikan käyttö vaikuttaa organisaation päätöksentekoon?”. Kysymys on jaettu kahteen alatutkimuskysymykseen, joista ensimmäinen on

”Miten lisättyä analytiikkaa voi hyödyntää päätöksenteossa?” ja toinen on ”Mitä lisätyn analytiikan onnistunut hyödyntäminen vaatii?”. Kysymyksiin lähdettiin vastaamaan kertomalla ensin organisaation päätöksentekorakenteista ja -tasoista. Organisaation päätöksenteon voi luokitella monella tavalla, mutta kenties yleisin ja lisätyn analytiikan kannalta oleellisin on luokittelu strategiseen, taktiseen ja operatiiviseen päätöksentekoon. Lisätyllä analytiikalla voidaan automatisoida kokonaan operatiivista päätöksentekoa. Strategisella ja taktisella päätöksentekotasolla lisätty analytiikka tukee päätöksentekijää.

Seuraavaksi käsiteltiin eri keinoja yhdistää lisätyn analytiikan tekoälyominaisuudet ja ihminen. Yhdistäminen voi tapahtua esimerkiksi karsimalla ensin vaihtoehtoja tekoälyllä, minkä jälkeen ihminen tekee lopullisen päätöksen. Ihmisen ja tekoälyn toimiva yhteistyö on yksi lisätyn analytiikan onnistumisen edellytyksistä. Tämän jälkeen käsiteltiin lisätyn analytiikan hyödyntämistä osana liiketoiminta-analytiikkasykliä. Lisätyllä analytiikalla voidaan tehostaa liiketoiminta-analytiikkasyklin kaikkia vaiheita, mutta osassa vaiheista ihmisen osallistuminen on edelleen tarpeellista.

Lopuksi tutkielmassa käsiteltiin lisätyn analytiikan onnistuneen hyödyntämisen edellytyksiä. Näitä on muun muassa datan valmistelu vinoumien välttämiseksi sekä järjestelmiin luottaminen. Luottamusta järjestelmiin voidaan parantaa lisäämällä algoritmien läpinäkyvyyttä. Tällöin voidaan välttää ns. musta laatikko -ilmiö, jossa tiedetään vain syöte ja tulos, mutta algoritmin toiminnasta ja tulokseen päätymisestä ei ole mitään tietoa. Lisätyn analytiikan mahdollisuuksien ja rajoitusten ymmärtäminen on myös oleellista, jotta tiedetään, mitä järjestelmiltä voi odottaa, ja ettei niihin luoteta sokeasti. Tekoäly ei myöskään vielä kykene eettisten näkökulmien huomioimiseen toiminnassaan. Ihminen on aina vastuussa tekoälyn tekemistä päätöksistä. Tämän vastuun ymmärtäminen on tärkeää, jotta lisättyä analytiikkaa voidaan hyödyntää eettisesti.

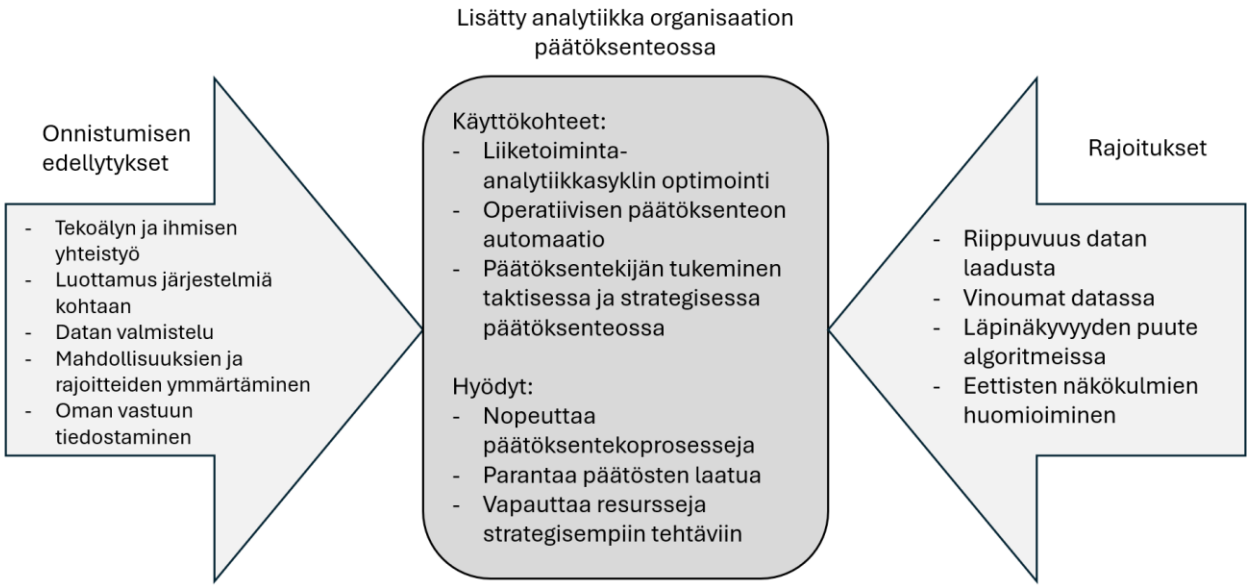

Kuva 4 Lisätyn analytiikan vaikutukset organisaation päätöksentekoon

Kuvassa 4 on esitetty vastaukset tutkimuskysymykseen 2 ja sen alatutkimuskysymyksiin. Johtopäätöksenä voidaan todeta, että lisätty analytiikka tuo merkittäviä hyötyjä organisaation päätöksentekoon, mutta sen onnistunut hyödyntäminen vaatii ponnisteluja, kuten työkalujen ymmärtämistä, laadukasta vinoumatonta dataa ja tiivistä yhteistyötä ihmisen kanssa. Lisätty analytiikka sopii parhaiten päätöksentekoa tukevaan rooliin ja vastuu päätöksistä säilyy ihmisellä.

Aiheen vähäisen tutkimuksen vuoksi jatkotutkimusmahdollisuudet ovat kattavat. Tekoäly ja sen kyvykkyydet kehittyvät jatkuvasti, joka heijastuu suoraan lisätyn analytiikan kehitykseen. Edistysaskeleet koneoppimisessa ja luonnollisen kielen prosessoinnissa avaavat uusia mahdollisuuksia lisätyn analytiikan työkaluille. Tämä tutkielma toteutettiin kirjallisuuskatsauksena, joka tarjoaa pohjan jatkotutkimukselle. Jatkotutkimus voitaisiin toteuttaa esimerkiksi case-tutkimuksena.

Lähteet

Abdul, A., Vermeulen, J., Wang, D., Lim, B. Y., & Kankanhalli, M. (2018). Trends and Trajectories for Explainable, Accountable and Intelligible Systems: An HCI Research Agenda. *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems*, 1–18. CHI '18: CHI Conference on Human Factors in Computing Systems. https://doi.org/10.1145/3173574.3174156

Afiouni, R. (2019). Organizational Learning in the Rise of Machine Learning. *ICIS 2019 Proceedings*. https://aisel.aisnet.org/icis2019/business_models/business_models/2

Aggarwal, C. C. (2023). *Neural Networks and Deep Learning: A Textbook*. Springer International Publishing. https://doi.org/10.1007/978-3-031-29642-0

Ahituv, N., Igbaria, M., & Sella, A. V. (1998). The Effects of Time Pressure and Completeness of Information on Decision Making. *Journal of Management Information Systems*, *15*(2), 153–172. https://doi.org/10.1080/07421222.1998.11518212

Alghamdi, N. A., & Al-Baity, H. H. (2022). Augmented Analytics Driven by AI: A Digital Transformation beyond Business Intelligence. *Sensors*, *22*(20), Article 20. https://doi.org/10.3390/s22208071

Andriole, S. J. (2019). Artificial Intelligence, Machine Learning, and Augmented Analytics [Life in C-Suite]. *IT Professional*, *21*(6), 56–59. IT Professional. https://doi.org/10.1109/MITP.2019.2941668

Augmented Analytics Is the Future of Data and Analytics. (ei pvm.). Gartner. Noudettu 2. joulukuuta 2024, osoitteesta https://www.gartner.com/en/documents/3773164

Caliskan, A., Bryson, J. J., & Narayanan, A. (2017). Semantics derived automatically from language corpora contain human-like biases. *Science (New York, N.Y.)*, *356*(6334), 183–186. https://doi.org/10.1126/science.aal4230

Chen, H., Chiang, R. H. L., & Storey, V. C. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, *36*(4), 1165–1188. https://doi.org/10.2307/41703503

Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, J. P. (2020). Introduction to Machine Learning, Neural Networks, and Deep Learning. *Translational Vision Science & Technology*, *9*(2), 14. https://doi.org/10.1167/tvst.9.2.14

Cremer, D. D., & Vandekerckhove, W. (2017). Managing unethical behavior in organizations: The need for a behavioral business ethics approach. *Journal of Management & Organization*, *23*(3), 437–455. https://doi.org/10.1017/jmo.2016.4

Davenport, T. H. (2018). *Rise of the Strategy Machines*. https://doi.org/10.7551/mitpress/11645.003.0005

Davenport, T. H., Harris, J. G., & Morison, R. (2010). *Analytics at Work: Smarter Decisions, Better Results*. Harvard Business Press.

Davenport, T. H., & Patil, D. J. (2012, lokakuuta 1). Data Scientist: The Sexiest Job of the 21st Century. *Harvard Business Review*. https://hbr.org/2012/10/data-scientist-the-sexiest-job-of-the-21st-century

Deep Learning. (ei pvm.). MIT Press. Noudettu 7. marraskuuta 2024, osoitteesta https://mitpress.mit.edu/9780262035613/deep-learning/

Duan, L., & Xu, L. D. (2012). Business Intelligence for Enterprise Systems: A Survey. *IEEE Transactions on Industrial Informatics*, *8*(3), 679–687. IEEE Transactions on Industrial Informatics. https://doi.org/10.1109/TII.2012.2188804

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*, *48*, 63–71. https://doi.org/10.1016/j.ijinfomgt.2019.01.021

Edwards, J. S., Duan, Y., & Robins, P. C. (2000). An analysis of expert systems for business decision making at different levels and in different roles. *European Journal of Information Systems*, *9*(1), 36–46. https://doi.org/10.1057/palgrave.ejis.3000344

Enholm, I. M., Papagiannidis, E., Mikalef, P., & Krogstie, J. (2022). Artificial Intelligence and Business Value: A Literature Review. *Information Systems Frontiers*, *24*(5), 1709–1734. https://doi.org/10.1007/s10796-021-10186-w

Epstein, R., Roberts, G., & Beber, G. (Toim.). (2009). *Parsing the Turing Test: Philosophical and Methodological Issues in the Quest for the Thinking Computer*. Springer Netherlands. https://doi.org/10.1007/978-1-4020-6710-5

Gartner Says More Than 40 Percent of Data Science Tasks Will Be Automated by 2020. (ei pvm.). Gartner. Noudettu 7. lokakuuta 2024, osoitteesta https://www.gartner.com/en/newsroom/press-releases/2017-01-16-gartner-says-more-than-40-percent-of-data-science-tasks-will-be-automated-by-2020

Ghasemaghaei, M., Ebrahimi, S., & Hassanein, K. (2018). Data analytics competency for improving firm decision making performance. *The Journal of Strategic Information Systems*, *27*(1), 101–113. https://doi.org/10.1016/j.jsis.2017.10.001

Grigorescu, A., Baiasu, D., & Chitescu, R. I. (2020). Business Intelligence, the New Managerial Tool: Opportunities and Limits. *Ovidius University Annals, Economic Sciences Series*, *XX*(1), 651–657.

Grover, V., Chiang, R. H. L., Liang, T.-P., & Zhang, D. (2018). Creating Strategic Business Value from Big Data Analytics: A Research Framework. *Journal of Management Information Systems*, *35*(2), 388–423. https://doi.org/10.1080/07421222.2018.1451951

Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, *61*, 000812561986492. https://doi.org/10.1177/0008125619864925

Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, *31*(3), 685–695. https://doi.org/10.1007/s12525-021-00475-2

Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, *61*(4), 577–586. https://doi.org/10.1016/j.bushor.2018.03.007

Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, *62*(1), 15–25. https://doi.org/10.1016/j.bushor.2018.08.004

Kreutzer, R. T., & Sirrenberg, M. (2020). *Understanding Artificial Intelligence: Fundamentals, Use Cases and Methods for a Corporate AI Journey*. Springer International Publishing. https://doi.org/10.1007/978-3-030-25271-7

Langley, A., Mintzberg, H., Pitcher, P., Posada, E., & Saint-Macary, J. (1995). Opening up Decision Making: The View from the Black Stool. *Organization Science*, *6*(3), 260–279.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. https://doi.org/10.1038/nature14539

Li, Y. (2017, tammikuuta 25). *Deep Reinforcement Learning: An Overview*. arXiv.Org. https://arxiv.org/abs/1701.07274v6

Mikalef, P., & Gupta, M. (2021). Artificial intelligence capability: Conceptualization, measurement calibration, and empirical study on its impact on organizational creativity and firm performance. *Information & Management*, *58*(3), 103434. https://doi.org/10.1016/j.im.2021.103434

Minsky, M., & Papert, S. (1988). *(1969) Marvin Minsky and Seymour Papert, Perceptrons, Cambridge, MA: MIT Press, Introduction, pp. 1-20, and p. 73 (figure 5.1).* https://doi.org/10.7551/mitpress/4943.003.0015

Oesterreich, T. D., Anton, E., & Xu, F. (2021). Augmenting the Future: An Exploratory Analysis of the Main Resources, Use Cases and Implications of Augmented Analytics. *ECIS 2021 Research Papers*. https://aisel.aisnet.org/ecis2021_rp/19

Prat, N. (2019). Augmented Analytics. *Business & Information Systems Engineering*, *61*(3), 375–380. https://doi.org/10.1007/s12599-019-00589-0

Project Ripasso | IBM. (2024, lokakuuta 21). https://www.ibm.com/products/project-ripasso

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*(6088), 533–536. https://doi.org/10.1038/323533a0

Samek, W., Montavon, G., Lapuschkin, S., Anders, C. J., & Müller, K.-R. (2021). Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications. *Proceedings of the IEEE*, *109*(3), 247–278. Proceedings of the IEEE. https://doi.org/10.1109/JPROC.2021.3060483

Seddon, P. B., Constantinidis, D., Tamm, T., & Dod, H. (2017). How does business analytics contribute to business value? *Information Systems Journal*, *27*(3), 237–269. https://doi.org/10.1111/isj.12101

Shneiderman, B., Plaisant, C., Cohen, M., Jacobs, S., Elmqvist, N., & Diakopoulos, N. (2016). Grand challenges for HCI researchers. *interactions*, *23*(5), 24–25. https://doi.org/10.1145/2977645

Shrestha, Y. R., Ben-Menahem, S. M., & von Krogh, G. (2019). Organizational Decision-Making Structures in the Age of Artificial Intelligence. *California Management Review*, *61*(4), 66–83. https://doi.org/10.1177/0008125619862257

Simon, H. A. (1987). Making Management Decisions: The Role of Intuition and Emotion. *Academy of Management Perspectives*, *1*(1), 57–64. https://doi.org/10.5465/ame.1987.4275905

Smith, J. F., Mitchell, T. R., & Beach, L. R. (1982). A cost-benefit mechanism for selecting problem-solving strategies: Some extensions and empirical tests. *Organizational Behavior and Human Performance*, *29*(3), 370–396. https://doi.org/10.1016/0030-5073(82)90251-3

Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, *59*, 433–460. https://doi.org/10.1093/mind/LIX.236.433

Uhrig, R. E. (1995). Introduction to artificial neural networks. *Proceedings of IECON ’95 - 21st Annual Conference on IEEE Industrial Electronics*, *1*, 33–37 vsk.1. https://doi.org/10.1109/IECON.1995.483329

Wamba-Taguimdje, S.-L., Wamba, S. F., Kamdjoug, J. R. K., & Wanko, C. E. T. (2020). Influence of artificial intelligence (AI) on firm performance: The business value of AI-based transformation projects. *Business Process Management Journal*, *26*(7), 1893–1924. https://doi.org/10.1108/BPMJ-10-2019-0411

Woiceshyn, J. (2011). A Model for Ethical Decision Making in Business: Reasoning, Intuition, and Rational Moral Principles. *Journal of Business Ethics*, *104*(3), 311–323. https://doi.org/10.1007/s10551-011-0910-1