



**TURUN
YLIOPISTO**
Kauppakorkeakoulu

Lisätyn analytiikan hyödyntäminen liiketoiminnassa

Tietojärjestelmätiede
kandidaatintutkielma

Laatija:
Leevi Räcköläinen

Ohjaaja:
FT Kai Kimppa

23.11.2023
Turku

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

Kandidatutkielma

Oppiaine: Tietojärjestelmätiede

Tekijä: Leevi Räcköläinen

Otsikko: Lisätyn analytiikan hyödyntäminen liiketoiminnassa

Ohjaaja: FT Kai Kimppa

Sivumäärä: 36 sivua

Päivämäärä: 23.11.2023

Tekoälyn- ja sitä hyödyntävän lisätyn analytiikan hyödyntäminen liiketoiminnassa voidaan nähdä merkittävänä tekijänä yritysten liiketoiminta-analytiikassa nykypäivänä. Lisättyä analytiikkaa hyödyntämällä yritykset voivat saavuttaa kilpailuetua markkinoilla. Lisätty analytiikka on vakiintunut käsitteenä 2010-luvun loppupuolella ja se on viimeisten vuosien aikana kasvattanut suosiotaan myös tieteellisen tutkimuksen kohteena. Suomenkielinen tutkimus aiheesta on vielä kovin vähäistä, mutta kansainvälisesti tekoälyn- ja analytiikan tutkimus on käsitelty aihetta kattavasti viimeisten vuosien aikana.

Tässä tutkielmassa käsitellään lisättyä analytiikkaa ja siihen olennaisesti liittyviä tekoälyä, koneoppimista, luonnollisen kielen käsittelyä. Tämän lisäksi syvennyttään liiketoiminta-analytiikkasykliin lisätyn analytiikan näkökulmasta keskittyen erityisesti yritysten päätöksentekoon sekä paneudutaan aiheeseen tarkemmin myös liiketoimintatiedon hallinnan välineiden sekä näissä erityisesti lisätyn analytiikan työkalujen toimintaan konkreettisin esimerkein.

Lisätty analytiikka tarjoaa yrityksille mahdollisuuden muokata liiketoiminta-analytiikkasykliä ja tämän avulla tehostaa prosessia kokonaisvaltaisesti esimerkiksi automatisoimalla työvaiheita, kuten liiketoimintaongelman ja sen tuomien mahdollisuuksien tunnistamisen tai tiedon hankinnan- ja louhinnan parissa, jolloin yrityksen resursseja voidaan ohjata uudelleen analytiikkasyklin vaiheisiin, jossa tekoälyä ei voida vielä hyödyntää niin kokonaisvaltaisesti ja ihmisen työpanos on tärkeämmässä roolissa.

Päätöksentekoon liittyen lisätyn analytiikan välineet eivät ainakaan toistaiseksi tarjoa yrityksille mahdollisuutta automatisoida liiketoiminta-analytiikkasyklin vaihetta täysin etenkin monimutkaisemmissa päätöksentekotilanteissa. Lisätty analytiikka tarjoaa kuitenkin monenlaisia päätöksentekijää tukevia välineitä- ja toimintoja, joiden avulla päätöksentekoa voidaan tehostaa erityisesti taktisella ja operatiivisella päätöksenteon tasolla.

Lisätyn analytiikan tehokas hyödyntäminen päätöksenteossa ja liiketoiminnassa yleisesti vaatii yrityksiltä tietynlaisia lähtökohtia, kuten tietynlaista tietoarkkitehtuuria, henkilöstön ammattitaitoa sekä selkeää johtamismallia, jonka perustana on vakiintuneet toimintatavat sekä tietynlainen suhtautuminen analytiikan suorittamiseen. Parhaimmassa tapauksessa yritykset voivat suoraviivaistaa toimintaansa ja saavuttaa kilpailuetua markkinoilla hyödyntämällä tekoälyä lisätyn analytiikan keinoilla tehostamalla liiketoiminta-analytiikkasykliä sekä parantamalla päätöksentekoa erityisesti taktisen ja operatiivisen päätöksenteon tasoilla.

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

Bachelor's thesis

Subject: Information Systems Science

Author: Leevi Rökköläinen

Title: Utilizing augmented analytics in business

Supervisor: PhD Kai Kimppa

Number of pages: 36 pages

Date: 23.11.2023

Artificial intelligence and augmented analytics can be seen as a remarkable and transforming factor in modern day business analytics. By utilizing augmented analytics companies can achieve competitive advantage in the market. Augmented analytics has been established as a concept in the end of the last decade and it has grown in popularity also in scientific research. Finnish research regarding the subject is still limited but internationally artificial intelligence and analytics research has studied the subject thoroughly.

This thesis discusses augmented analytics and related artificial intelligence, machine learning, and natural language processing. On top of that the thesis takes a deeper look into the business analytics cycle with a focus on augmented analytics and decision making especially through the adaptations of business intelligence tools and augmented analytics in that respect through real life examples.

Augmented analytics offers business' the possibility to modify the business analytics cycle and through that enhance the process by, for example automating operations like the identification of business problems and possibilities and data processing. By doing so companies can redirect resources to stages of the business analytics cycle in which AI and augmented analytics can't yet be utilized so vastly and human input is more vital.

Regarding decision making augmented analytics is at least not yet offering companies the possibility to automate the stage of the business analytics cycle completely especially in the more complex decision-making situations. Though augmented analytics offers a variety of decision supporting tools and ways or working with which decision making can be enhanced especially in tactical and operational decision-making levels.

Utilizing augmented analytics in decision making and in business altogether requires a specific set of starting points from companies. These are for example a specific type of information architecture, skillful workforce, clear way of leadership that enforces a clear way of working and open mind about working with analytics. In the best-case scenario companies can streamline and achieve competitive advantage in the markets by utilizing artificial intelligence and augmented analytics enhancing their business analytics cycle and improving decision-making especially in tactical and operational levels of decision making.

Keywords: Augmented analytics, business, business analytics, business intelligence, artificial intelligence, decision making.

SISÄLLYS

1	Johdanto	7
	1.1 Johdatus aiheeseen	7
	1.2 Tutkimuskysymys, rajaukset ja rakenne	7
2	Tekoälyn soveltaminen analytiikassa	9
	2.1 Liiketoimintatiedon hallinta	10
	2.2 Tekoäly	11
	2.3 Koneoppiminen	12
	2.4 Syväoppiminen	13
	2.5 Luonnollisen kielen käsittely	13
	2.6 Lisätty analytiikka	16
3	Lisätty analytiikka liiketoiminnassa	18
	3.1 Liiketoiminta-analytiikkasykli	18
	3.2 Tekoäly analytiikkasyklin eri vaiheissa	20
	3.3 Päätöksenteon kehittäminen lisätyn analytiikan avulla	23
	3.4 Lisätyn analytiikan hyödyntäminen liiketoiminnassa	26
4	Yhteenveto ja johtopäätökset	30
	Lähteet	34

KUVIOT

- Kuvio 1. Lisätty analytiikka, Alghamdi & Al-Baity (2022) muokattu. 9
- Kuvio 2. Liiketoiminta-analytiikkasykli, (engl. the business analytics cycle), Storey & Song (2017) muokattu. 19
- Kuvio 3. Päätöksenteko organisaatiossa, Harrington & Ottenbacher (2019) muokattu. 24
- Kuvio 4. Lisätyn analytiikan hyödyntäminen liiketoiminnassa. Edwards ym. (2000), Chen ym. (2012), Cordoba (2014), Barton & Court (2018), Benke & Benke (2018), Duan ym. (2019), Albrect ym. (2021), Alghamdi & Al-Baity (2022), muokattu. 29

TAULUKOT

- Taulukko 1 Tekoälysovellukset analytiikkasyklin eri vaiheissa. (Prat 2019 Muokattu). 21

1 Johdanto

1.1 Johdatus aiheeseen

Analytiikan hyödyntäminen antaa yrityksille mahdollisuuden saavuttaa kilpailuetua markkinoilla (Alghamdi & Al-Baity 2022). Lisätyn analytiikan (engl. augmented analytics, AA) uskotaan olevan merkittävä tekijä tulevaisuudessa yritysten uudistaessa liiketoiminta-analytiikan toimintoja ja liiketoimintatiedon hallinnan (engl. business intelligence, BI) ratkaisuja (Sallam 2019). Kandidaatintutkielmani tarkoituksena on tutkia tätä ilmiötä ja erityisesti sitä, miten tekoäly (engl. artificial intelligence, AI) ja sitä hyödyntävä lisätty analytiikka voi auttaa yrityksiä tekemään analyysi- ja päätöksentekoprosesseistaan tehokkaampia.

Tutkielman aihe on merkittävä, sillä massadatan merkityksen (engl. big data) sekä ns. self-service BI:n yleistyessä yritysten tarve tehokkaalle ja tarkalle analyysille on entistä kovempi (Alghamdi & Al-Baity 2022). Aihe on minulle myös henkilökohtaisesti merkittävä, sillä oma motivaationi aihetta kohtaan kumpuaa omista kokemuksista niin opintojen, kuin myös työelämän puolelta. Opinnoista olen saanut laajan kosketuspinnan esimerkiksi erilaisiin BI-työkaluihin sekä niiden käyttöön niin ad hoc -tyylisesti, kuin lisätyn analytiikan toimintoja hyödyntäen. Työelämässä kuitenkin olen kohdannut todellisuuden, joka näyttää valitettavasti siltä, ettei liiketoiminta-analytiikassa aina hyödynnetä kaikkia mahdollisia välineitä eikä niiden ominaisuuksia prosessin tehostamiseksi vaan tukeudutaan enemmän vakiintuneisiin tapoihin ja välineisiin. Tämä johtaa valitettavan usein siihen, että prosessit eivät ole kovinkaan optimaalisia ja kilpailuetu siirtyy niille toimijoille, jotka maksimoivat lisätyn analytiikan hyödyt toiminnassaan.

1.2 Tutkimuskysymys, rajaukset ja rakenne

Tutkielman tutkimuskysymykset ovat:

1. Miten lisättyä analytiikkaa voidaan hyödyntää liiketoiminnan apuna?
 - a. Mitä on lisätty analytiikka?
 - b. Miten tekoäly voi auttaa päätöksenteossa?

Lisättyä analytiikkaa hyödyntävien alustojen avulla pystytään ratkaisemaan liiketoimintaan liittyviä ongelmia monialaisesti ja nopeuttamaan päätöksentekoprosessia (Pribisalić ym. 2019). Tähän peilaten tutkielmassa keskitytään päätöksentekijöiden näkökulmaan sekä liiketoiminta-analytiikan osalta erityisesti päätöksentekoprosessin tehostamiseen sekä lisätyn analytiikan vaikutuksiin myös päätösten laadun osalta. Tutkielmassa ei sen laajuuden vuoksi keskitytä lisätyn analytiikan hyödyntämiseen liittyviin mahdollistaviin tai rajoittaviin tekijöihin. Lisäksi tutkielman aihe rajataan käsittelemään pääasiassa BI ratkaisuja, niiden toimiessa liiketoiminta-analytiikan pääasiallisina työvälineinä nykypäivänä.

Tutkielma koostuu johdannon lisäksi kolmesta varsinaisesta sisältöluvusta, joissa esitellään käsiteltävät aiheet perusteellisesti sekä vastataan tutkimuskysymyksiin. Ensimmäinen varsinainen sisältöluke on luku 2. ”Tekoälyn soveltaminen lisätyssä analytiikassa”. Tässä luvussa esitellään lisätty analytiikka sekä siihen keskeisesti liittyvien aiheiden perusteet kuten tekoäly, koneoppiminen sekä luonnollisen kielen käsittely ja BI.

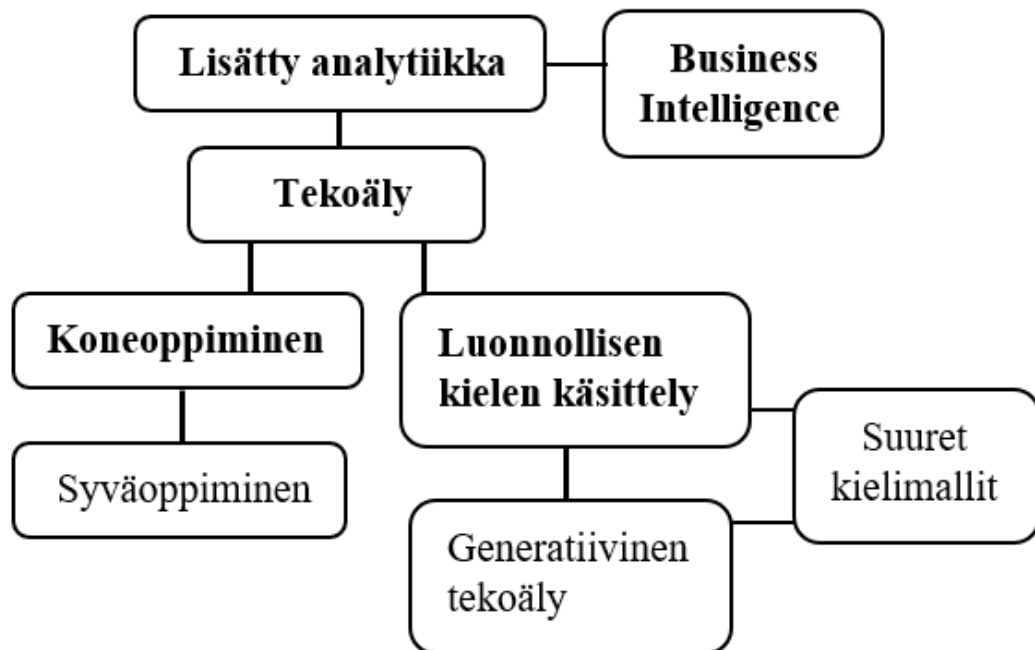
Luku 3. ”Lisätty analytiikka liiketoiminnassa” käsittelee tutkielman aihetta tarkemmin liiketoiminta-analytiikan näkökulmasta, kiteyttäen jo esille tulleita asioita, keskittyen erityisesti liiketoiminta-analytiikkasykliin (engl. business analytics cycle) ja siihen, kuinka tekoäly ja tässä tapauksessa sitä hyödyntävä lisätty analytiikka vaikuttaa prosessin eri vaiheisiin sekä päätösten luotettavuuteen ja laatuun. Tämän lisäksi kolmas luku vastaa varsinaiseen tutkimuskysymykseen: ”Miten lisättyä analytiikkaa voidaan hyödyntää liiketoiminnan apuna?” Luku keskittyy erityisesti päätöksentekoprosessiin sekä päätöksentekijän näkökulmaan ja tuo esille myös käytännön esimerkkejä. Luvun lopussa esitetään tehdyn kirjallisuuskatsauksen pohjalta viitekehys, jolla havainnollistetaan lisätyn analytiikan hyödyntämistä liiketoiminnassa.

Neljäs ja viimeinen luku ”Yhteenveto ja johtopäätökset” kiteyttää tutkielman kokonaisuudessaan sekä esittää keskeiset johtopäätökset ja tutkielman esille tuomat asiat omassa luvussaan. Viimeisessä luvussa pohditaan myös mahdollisia jatkotutkimusaiheita. Tutkielman lopussa on lähdeluettelo, josta selviää tutkielmassa käytettyjen lähteiden alkuperä hyvän tieteellisen viittaustavan mukaisesti.

2 Tekoölyn soveltaminen analytiikassa

Tämä luku esittelee lisätyn analytiikan käsitteen sekä siihen olennaisesti liittyvät termit ja aihepiirit. Gartner (2017) esitteli lisätyn analytiikan käsitteen ensimmäisen kerran. Jotta voimme ymmärtää lisättyä analytiikkaa, tulee ymmärtää tarkemmin BI:n käsite sekä sen historia ja kehitysvaiheet ennen lisättyä analytiikkaa. Alakäsitteiden ymmärrys on merkittävää, sillä lisätty analytiikka hyödyntää sekä BI:n, että tekoölyn edistyneitä ominaisuuksia liiketoimintatiedon, datan muokkaamisessa hyödylliseksi informaatioksi päätöksenteon tueksi (Alghamdi & Al-Baity 2022).

BI:n käsitteen selittämisen lisäksi tässä luvussa esitellään pintapuolisesti tekoöly ja sitä hyödyntävät koneoppiminen, syväoppiminen ja luonnollisen kielen käsittely sekä generatiivinen tekoöly. Lisättyyn analytiikkaan paneudutaan tarkemmin viimeisessä alaluvussa, kun siihen liittyvät keskeiset käsitteet on aiemmissa alaluvuissa esitelty. Edellä oleva kuvio havainnollistaa pääpiirteittäin lisätyn analytiikan käsitettä sekä siihen olennaisesti liittyviä aihepiirejä.



Kuvio 1. Lisätty analytiikka, Alghamdi & Al-Baity (2022) muokattu.

2.1 Liiketoimintatiedon hallinta

BI kattaa teknologiat, tekniikat, järjestelmät, toimintatavat sekä metodiikat, joiden avulla kyetään analysoimaan sekä ymmärtämään merkittävää liiketoimintatietoa ja tekemään sen pohjalta liiketoiminnan kannalta tärkeitä päätöksiä oikealla tavalla ja oikeaan aikaan on kasvattanut suosiotaan merkittävästi yritysten keskuudessa (Chen ym. 2012). BI:n historia ja eri vaiheet voidaan jaotella karkeasti kolmeen osaan, jotka ovat: BI 1.0, BI 2.0 ja BI 3.0 (Alghamdi & Al-Baity 2022).

BI 1.0 koetaan sen syntymävaiheena ja nimitystä käytetään usein kuvaamaan BI:tä ennen nykypäivää. BI 1.0 keskittyy 1980- ja 1990- luvuille, jolloin yritykset alkoivat ensi kertaa hyödyntämään tietokoneita datan prosessoimisessa. BI 1.0:n tunnusmerkkejä ovat yleisesti: relaatiotietokantojen ja tietovarastojen (engl. data warehouse) yleistyminen. BI 1.0:n aikana työkaluilla tehty raportointi koostui valmiista, staattisista raporteista, joita oli haastava muokata. Muokkaaminen ja raportointi tapahtui tässä vaiheessa pääasiassa IT-ammattilaisten toimesta. (Chen ym. 2012; Alghamdi & Al-Baity 2022.)

BI 2.0 katsotaan yleisesti sijoittuvan ajalle 1990-luvun lopusta 2010-luvulle. BI 2.0:n myötä BI:stä tuli käyttäjäystävällisempi sekä edistyneempi työkalu liiketoimintatiedon hallintaan (Bulusu ym. 2020). Alghamdin ja Al-Baityn (2022) mukaan tässä vaiheessa tietovarastot olivat vakiintunut osa prosessia ja ne mahdollistivat keskittyneemmän datahallinnan, joka nopeutti ja helpotti prosessia merkittävästi. Tietovarastoihin liittyy olennaisesti myös ns. OLAP-tietokantatekniikka (engl. Online Analytical Processing) - tietokantatekniikka. OLAP tarkoittaa käytännössä tekniikkaa, jolla pystytään hallitsemaan suuria datamääriä esimerkiksi yrityksen tietokannoissa jakamalla ne ”kuutioihin”, joissa tieto on organisoitu loogisesti moniulotteiseen muotoon, joka muistuttaa kuutiota ja se on helposti saatavissa. Datan kuutiointi antaa mahdollisuuden nopeaan tarkasteluun ja analysointiin, koska sillä voidaan jakaa esimerkiksi myyntidata kuutioihin eri ulottuvuuksien kesken ja tarkastella näitä yhdessä ja erikseen yhdistelemällä ja erottelemalla kuutioita. (Chaudhuri ym. 1997.) Siirryttäessä BI 1.0:sta kohti BI 2.0:aa BI muuttui vanhasta staattisesta, pääasiassa IT-ammattilaisten hallinnoimasta raportoinnista kohti self-service BI:tä, joka mahdollisti käyttäjien raporttien muokkaamisen ilman varsinaista IT-asiantuntemusta. Samalla BI-työkaluista tuli monin puolin helppokäyttöisempiä mahdollistaen intuitiivisen käytön. (Prat 2019; Alghamdi & Al-Baity 2022.)

BI 3.0 alkoi 2010-luvulla ja sen aikakausi jatkuu edelleen. Lisätty analytiikka on merkittävä osa tätä BI:n ”tulevaisuutta”, jossa korostuu sen sovelluspohjaisuus, nopeus sekä erityisesti automaatio, jonka tekoälyn sovellukset mahdollistavat (Alghamdi & Al-Baity 2022). BI 3.0:aan liittyy olennaisesti erinäiset tekoälysovellukset, kuten koneoppiminen sekä luonnollisen kielen käsittely, joista lisää seuraavissa alaluvuissa.

Käytännössä liiketoimintatiedon hallintaa, BI:tä tehdään yrityksissä useiden sovellustarjoajien tuottamien palveluiden kautta. Merkittävimpiä BI-sovelluksia ovat muun muassa Microsoftin Power BI, Salesforcein Tableau sekä Qlik:in Qlik Sense. (Richardson ym. 2020.)

2.2 Tekoäly

Tekoälylle ei ole yksiselitteistä määritelmää. Yleisesti voidaan kuitenkin sanoa, että tekoälyllä tarkoitetaan käytännössä tietojärjestelmiä, joilla on kyky tehdä päätelmiä sekä toimia tehtyjen päätösten perusteella ihmisten tai ihmisaivojen tavoin. Käytännössä tämä saavutetaan, kun tekoälyjärjestelmillä käsitellään suuria datamääriä. (Rana ym. 2022.) Tekoäly on siis järjestelmä, jolla on teoreettiset valmiudet analysoida sekä tulkita käsittelemäänsä tietoa, oppia uusia asioita tämän tiedon perusteella sekä käyttää saamaansa oppia sille annettujen tavoitteiden ja tehtävien saavuttamiseksi. Tekoälyn toiminnassa olennaista on algoritmit, joita se käyttää sekä oppimisprosessissa että sille annettujen tehtävien ratkaisussa. Käytännössä algoritmien avulla tekoäly kykenee oppimaan aikaisemmista kokemuksistaan. Algoritmit toimivat siis tekoälyn ohjesääntöinä, jotka sanelevat miten se toimii. Nämä ohjesäännöt kasaantuvat järjestelmään toistensa päälle siten, että vahvemmat sekä kehittyneemmät algoritmit nousevat heikompien algoritmien päälle, jolloin tekoäly kehittyy. (Watson 2019; Rana ym. 2022.)

Tekoäly voidaan nähdä ylätasoinen käsitteenä tekniikoille, jota se toiminnassaan hyödyntää. Näistä olennaisin on koneoppiminen (engl. machine learning) sekä sen alalaji syväoppiminen (engl. deep learning) (Watson 2019). Seuraavat alaluvut esittelevät nämä käsitteet, jotta tekoälyn kokonaisuus on ymmärrettävissä paremmin.

2.3 Koneoppiminen

Koneoppiminen (engl. Machine Learning, ML) on tekniikan ala, joka keskittyy rakentamaan tietokoneita, jotka pystyvät kehittymään automaattisesti kokemuksen kautta (Jordan ym. 2015). Koneoppiminen on yksi merkittävimmistä tekoälyn osa-alueista. Somersin (2017) mukaan 2010-luvun saavutukset etenkin koneoppimisen alalajin, syväoppimisen parissa ja viime aikojen tekoälyn uusi tuleminen ovat pitkälti syväoppimisen kehittäjän Geoffrey Hintonin työn ansiota.

Koneoppimisen perustana pidetään yhdistelmää, joka koostuu sekä tilastollisista että matemaattisista malleista algoritmeista. Koneoppimisen taustalla on ajatus järjestelmästä, joka oppii ja pystyy täten kehittämään itseään ilman, että järjestelmään erikseen ohjelmoidaan esimerkiksi tiettyjä toimintatapoja tietyissä tilanteissa. (Jordan ym. 2015; Watson 2019.) Watsonin (2019) mukaan koneoppimisen avulla pystytään tehokkaasti automatisoimaan prosesseja. Esimerkiksi kun järjestelmä on ”oppinut” mitä sen tulee tehdä tietynlaisilla tiedoilla, voidaan tilanne automatisoida, koska järjestelmä osaa tunnistaa tilanteen ja soveltaa oppimaansa.

Tekoälyn uusi tuleminen on kiihtynyt entisestään ja etenkin viimeisen vuoden aikana ilmestyneet tekoälysovellukset, kuten Open AI:n Chat GPT ovat malliesimerkkejä tästä ilmiöstä. Tähän liittyy olennaisesti massadata, joka tarkoittaa käytännössä sitä, että jatkuvasti enemmän ja enemmän saatavilla olevaa erittäin suurta datamäärää kerätään, säilötään, analysoidaan ja hyödynnetään erilaisiin tarkoituksiin (Kofi ym. 2022). Koneoppimisen avulla voidaan opettaa järjestelmää käsittelemään suuria datamääriä tehokkaammin. Suuret yritykset, kuten Google ja Amazon pyrkivät saamaan kaiken mahdollisen hyödyn irti suurista datamääristä maksimoidakseen liiketoiminnallisen hyödyn (Somers 2017). Koneoppimisen kehitykseen viime vuosina liittyy olennaisesti myös tietokoneiden tehokkuuden kasvu, jatkuva, koko maailman laajuinen internet yhteys sekä avoin lähdekoodi, joka mahdollistaa massadataliön ja sen seurauksena koneoppimisen sekä sitä hyödyntävien tekoälysovellusten kehityksen (Kofi ym. 2022).

Koneoppimisella on useita eri alalajeja. Tärkeimmät varsinaiset koneoppimisen alalajit ovat vahvistettu (engl. reinforcement), ohjattu (engl. supervised) sekä ohjaamaton (engl. unsupervised) oppiminen. Käytännössä ohjattu oppiminen tarkoittaa toimintatapaa, jossa järjestelmälle annetaan suuri määrä dataa sekä vastaukset, joiden perusteella järjestelmän tulee toimia. Ohjaamattomassa oppimisessa järjestelmä saa ainoastaan suuren määrän

dataa, ilman vastauksia, jolloin järjestelmä oppii datan rakenteen mukaan tulkitsemaan ja saamaan oikeat vastaukset. Vahvistettu oppiminen hyödyntää sekä ohjatun, että ohjaamattoman oppimisen periaatteita, joka tarkoittaa sitä, että järjestelmä saa vasta suorittamansa toimenpiteen eli esimerkiksi luokittelun jälkeen tietää oliko tehty arvio oikea vai ei. Eli vahvistetussa oppimisessa järjestelmä ei saa suoria vastauksia sille syötetyn datan mukana. (Jordan ym. 2015; Somers 2017; Watson 2019.)

2.4 Syväoppiminen

Kuten jo mainittu, on syväoppiminen koneoppimisen alalaji. Syväoppimisesta puhutaan usein myös keinotekoisien neuroverkkojen käsitteellä. Syväoppiminen on mahdollisesti jopa merkittävin tekoälyn taustalla vaikuttavista erillisistä koneoppimisen sovelluslajeista. Käytännössä kaikki edistyneet tekoälyalgoritmit hyödyntävät keinotekoisia neuroverkkoja. Somersin (2017) mukaan keinotekoinen neuroverkko on tietynlainen jäljennös ihmisen aivojen hermoverkoista, joka koostuu erilaisista osista ja kerroksista, jotka ovat yhteydessä toisiinsa muodostaen ihmisaivoja mukailevan kokonaisuuden. Syväoppimisen toimintaperiaate esitellään usein tietynlaisen kerroksittaisen rakenteen avulla. Tarkemmin katsottuna neuroverkon algoritmi koostuu suuresta määrästä erilaisia kerroksia, jotka muodostavat keinotekoisien neuroverkkojen. Nämä kerrokset ovat toisiinsa yhteydessä solmukohtien avulla. Neuroverkko osaa säätää ja muuttaa toimintaansa tilanteen mukaan järjestämällä kerrosten sekä solmukohtien rakennetta tilanteen mukaan. (Jordan ym. 2015; Somers 2017.)

Syväoppimisalgoritmi on tehokkaampi kuin perinteiset koneoppimisalgoritmit, sillä sen rakenteen ja toimintaperiaatteen ansiosta se pystyy analysoimaan ja suorittamaan sille annettuja tehtäviä huomattavasti tehokkaammin myös suuremmasta datamäärästä. Tämä mahdollistaa myös syväoppimisalgoritmin kyvyn tehdä kattavia ennustuksia saamansa datan perusteella, sillä se hyödyntää toiminnassaan tehokkaasti aiemmin oppimaansa. (Watson 2019.)

2.5 Luonnollisen kielen käsittely

Luonnollisen kielen käsittely (engl. natural language processing, NLP) on tekoälyn osa-alue, joka keskittyy tietokoneiden ja ihmiskielen väliseen kommunikaatioon. Käytännössä luonnollisen kielen käsittely sijoittuu tietojenkäsittelytieteen- ja tietokonekielen väliin keskittyen kirjoitetun ja puhutun kielen prosessoimiseen

ymmärrettäväksi, kompaktiksi dataksi. Luonnollisen kielen käsittelyn avulla pystytään tänä päivänä suorittamaan monenlaisia tehtäviä, kuten erilaisia tekstin kategorisointi, tunnistus, sekä käännöstehtäviä. (Hamilton ym. 2022; Fanni ym. 2023.)

Ensimmäiset laskennalliset mallit (engl. computational model) esiteltiin 1960-luvulla. Hamilton ym. (2022) mukaan tätä pidetään yleisesti luonnollisen kielen käsittelyn ensiaskelina, vaikka kielentutkimus on eri muodoissa ollut olemassa jo tuhansia vuosia. NLP-sovelluksia on aikojen saatossa ollut monenlaisia ja tänä päivänä esimerkiksi verkkokaupassa toimiva chat-bot, eli tietokoneohjelma, joka on tarkoitettu auttamaan sen kanssa keskustelevaa ihmistä lisäkysymyksin ja vastauksin (Fanni ym. 2023) on luonnollisen kielen käsittelyn aikaansaannos.

Hamiltonin ym. (2022) mukaan luonnollisen kielen käsittely on kehittynyt vaiheittain. Tärkeimpiä kehitysaskelia kohti tämän päivän luonnollisen kielen käsittelyä ovat olleet muun muassa Noam Chomskyn kehittämä Universaalinen Sanaston (engl. universal grammar), jonka ansiosta pystyttiin kehittämään monimutkaisempia ja kielellisesti kehittyneempiä järjestelmiä 1970- ja 1980-lukujen aikana. 1990- ja 2000-luvun aikana tapahtunut ”statistinen vallankumous” sekä koneoppimisen syntyminen ajoi luonnollisen kielen käsittelyn uudelle tasolle. (Hamilton ym. 2022.)

Tämän ajanjakson aikana NLP:n kehitys keskittyi luonnollisen kielen ymmärtämisen (engl. natural language understanding, NLU) hyödyntämiseen ja 2010-luvun puolella IBM:n kehittämä Watson DeepQA järjestelmä esitteli aivan uudenlaisen tavan hyödyntää kielen käsittelyn eri tapoja luonnollisen kielen kehityksen alalla. Muun muassa Watson DeepQA:n, neurosymbolisen kysymys-vastausohjelmiston myötä luonnollisen kielen käsittelyn alalla päästiin sen nykyvaiheeseen, joka hyödyntää toiminnassaan seuraavia osa-alueita: jo mainittu NLU, luonnollisen kielen tuottaminen (engl. natural language generation, NLG) ja luonnollisesta kielestä päättelyksi (engl. natural language inference, NLI) (Hamilton ym. 2022). Hamilton ym. (2022) mukaan nämä tekniikat, sekä koneoppimisen hyödyntäminen kielen käsittelyn ”uudessa ajassa” puskee tieteenalaa eteenpäin. Tässä kehityksessä on avainasemassa generatiivinen tekoäly, josta enemmän luvun lopussa.

Luonnollisen kielen kehitys tänä päivänä keskittyy erityisesti lähestymistapoihin, joiden avulla voidaan harjoittaa loogista päättelyä (Hamilton ym. 2022; Fanni ym. 2023). Käydään seuraavaksi lyhyesti läpi NLP:n keskeisten osa-alueiden periaatteet.

Hamiltonin ym. (2022) mukaan luonnollisen kielen ymmärtäminen on yksi laajimmista luonnollisen kielen käsittelyn osa-alueista, joka pyrkii selittämään semantiikkaan ja merkityksen ymmärtämiseen liittyviä käsitteitä puhutusta tai kirjoitetusta kielestä. Perinteisen luonnollisen kielen käsittelyn ja ymmärtämisen käsitteitä on yleisesti haastavaa erottaa, sillä niiden perustoimintaperiaatteissa on paljon yhtäläisyyksiä.

Luonnollisen kielen päättelyn käsitteeseen yhdistetään yleisesti erilaiset informaation hakemiseen, järjestämiseen liittyvät toimintatavat sekä konekäyttäminen ja koneen luetun ymmärtäminen, kysymyksiin vastaaminen. Luonnollisen kielen päättelyn avulla pyritään todistamaan, pitääkö hypoteesi paikkaansa jossain annetussa tilanteessa ja voidaanko tämä päätellä loogisesti aloitustilanteesta. (Hamilton ym. 2022). Esimerkkinä päättelytehtävästä voidaan pitää lähtökohtaa ”Ville on Laurin isä”, joka loogisesti sisältää väitteen ”Ville on isä”. NLI keskittyy tämän yksinkertaistetun esimerkin kaltaisten loogisten päättelyketjujen ratkaisemiseen.

Viimeisempänä luonnollisen kielen käsittelyn tärkeimpänä osa-alueena Hamilton ym. (2022) esittää luonnollisen kielen tuottamista, jonka peruseriaate on nimensä mukaisesti tekstin tai puheen generointi, luonti ei-kiellellisestä, strukturoidusta datasta. Tämä lähestymistapa voidaan nähdä päinvastaisena NLU:n lähestymistapaan, jossa käytetty data on luonnollista kieltä. Kovan suosion saavuttanut OpenAI:n GPT3 kielimalli on esimerkki sovelluksesta, joka hyödyntää sekä NLU:n, että NLG:n lähestymistapoja kielen käsittelyyn generatiivisen tekoälyn avulla, josta enemmän seuraavaksi.

Puhuttaessa generatiivisesta tekoälystä nousee usein esille suurten kielimallien käsite. Suuret kielimallit (engl. large language models, LLM) liittyvät olennaisesti luvussa 2.3 esitettyihin syväoppimiseen sekä NLG:hen. Suuret kielimallit ovat tekoälymalleja, jotka pohjautuvat syväoppimiseen. Käytännössä malli opetetaan esimerkiksi suorittamaan sille annettuja tehtäviä ja esimerkiksi vastaamaan kysymyksiin. (Kasneci ym. 2023.) Rubyn (2023) mukaan suurten kielimallien toiminnan taustalla on syväoppimisen sekä luonnollisen kielen käsittelyn menetelmien yhdistelmä, jonka avulla mallit kykenevät suorittamaan monimutkaisia päättelyprosesseja ja eri sanojen yhteyksiä niihin syötetyn suuren datamäärän avulla. Kuten jo mainittu on OpenAI:n kehittämä ChatGPT malli esimerkki suuresta kielimallista, joka kykenee suorittamaan edellä mainittuja tehtäviä. Tämänlaisia malleja kutsutaan yleisesti myös nimellä generatiivinen tekoälymalli.

2.6 Lisätty analytiikka

Lisätty analytiikka mahdollistaa analytiikkaprosessin laaja-alaisen automatisaation tekoälyn avulla (Prat 2019). Aiemmissä alaluvuissa esiteltyt koneoppiminen (ML) sekä luonnollisen kielen käsittely (NLP) ovat olennaisimmat tekoälysovellukset, joilla lisätty analytiikka mullistaa perinteisen liiketoiminta-analytiikan. Tässä alaluvussa esitetään lisätyn analytiikan käsite ja sen käytännön sovellukset tarkemmin, kun siihen olennaisesti liittyvät käsitteet ja termit on aiemmissä alaluvuissa määritelty.

Kuten 2.1 alaluvussa nähtiin, on lisätty analytiikka merkittävä osa BI 3.0 aikakautta. Tämä tekoälyn ehostaman analytiikan aikakausi on jatkumoa BI 1.0:lle, jonka tunnusmerkkeihin kuului tietovarastojen syntyminen 1990-luvulla sekä BI 2.0, jonka tunnusmerkkejä ovat analytiikan suosion kasvu 2000-luvulla sekä massadatan merkityksen kasvu 2010-luvulla. BI 2.0:n aikakaudella yleistyi myös ns. self-service BI, joka mahdollisti analytiikan ja BI:n harjoittamisen myös tavanomaisemmilta käyttäjiltä, ilman laajaa tietoteknistä osaamista. (Alpar & Schulz 2016.)

BI 3.0:n suurin muutos verrattuna aiempiin aikakausiin on tekoälyn ehostama analytiikka (engl. AI-powered analytics), jota kutsutaan myös nimellä lisätty analytiikka. Tämä kehityssuunta on mahdollistanut uusia mahdollisuuksia myös self-service BI:n käytössä, kun käyttäjät ovat päässeet tekoälyn avulla entistä nopeammin ja helpommin käsiksi arvokkaaseen informaatioon edistyneen analytiikan avulla (Alpar & Schulz 2016). Pratin (2019) mukaan tämän seurauksena on esitelty myös uusi käsite: ”citizen data scientist” eli natiivi datatieteilijä, joka tarkoittaa käytännössä henkilöä, joka BI:n ja analytiikan uudella aikakaudella pystyy ”luomaan tai tekemään malleja, jotka hyödyntävät edistyneitä analytiikan ominaisuuksia, ilman että kyseisen henkilön työnkuva keskittyy pääasiallisesti statistiikkaan tai analytiikkaan.”

Knighatin (2017) mukaan BI:n uudella aikakaudella on kuitenkin oma ongelmansa. Tekoälyn ehostamaan analytiikkaan suhtaudutaan varauksellisesti ja sitä ei välttämättä hyödynnetä, sillä alalla on pula data-analytiikan asiantuntijoista (engl. data scientist). Pratin (2019) mukaan tämä johtuu osaltaan myös siitä, että yksinkertaisesti datan määrän ollessa niin suuri, voi sen hallinta vaikuttaa lähes mahdottomalta organisaatioille ja yksilöille, joilla ei ole laajaa asiantuntemusta aiheen parista. Tähän ongelmaan on mahdollista löytää vastaus lisätystä analytiikasta, jonka avulla on mahdollista optimoida ja hyödyntää dataa päätöksenteon kontekstissa automaation avulla.

Hyödyntämällä lisättyä analytiikkaa, yritykset voivat parhaassa tapauksessa automatisoida tiedonvalmistelu prosessin lähes kokonaan sekä saada tarkempaa, nopeampaa tietoa haluamastaan datasta (Alghamdi & Al-Baity 2022). Luvuissa 3.1 ja 3.2 käydään tarkemmin läpi liiketoiminta-analytiikkasykliä (engl. business analytics cycle) ja sitä miten lisätty analytiikka voi tehostaa prosessia sen jokaisessa vaiheessa erilaisten tekoälysovelluksien avulla. Alghamdin ja Al-Baityn (2022) mukaan yleisellä tasolla voidaan kuitenkin sanoa, että hyödyntämällä lisättyä analytiikkaa liiketoiminta-analytiikkasyklissä voidaan saavuttaa suurta hyötyä ja samalla säästää myös resursseja esimerkiksi implementoimalla tekoälyä hyödyntäviä sovelluksia osaksi prosessia etenkin tiedonvalmisteluvaiheessa, joka vapauttaisi analyytikoille aikaa ja sitä kautta työpanosta prosessin muihin vaiheisiin.

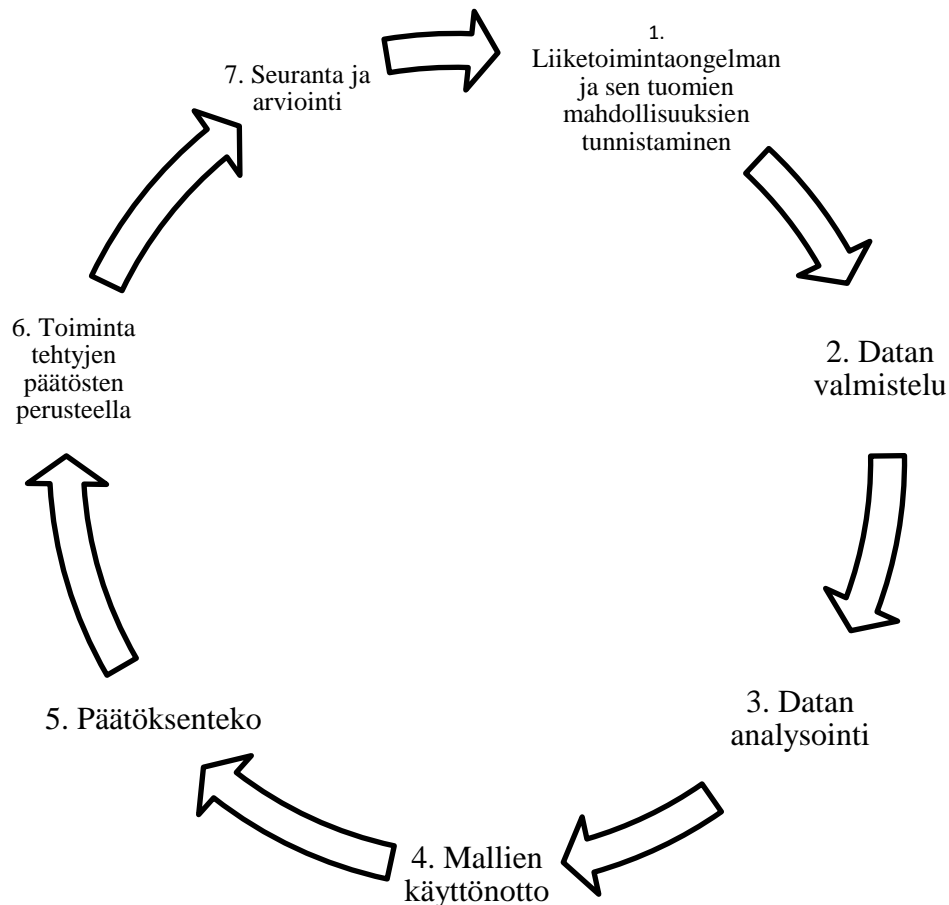
Käytännössä lisätty analytiikka hyödyntää toiminnassaan aiemmissä alaluvuissa esiteltyä tekoälyä, koneoppimista sekä luonnollisen kielen käsittelyä. Verrattuna BI 2.0 sukupolveen ja self-service BI:n mahdollisuuksiin lisätyn analytiikan avulla on mahdollista hyödyntää tekoälyalgoritmeja tiedonvalmisteluprosessin tehostamisessa, tietovarastojen siistimisessä. Koneoppimisen osalta lisätty analytiikka mahdollistaa ns. AutoML algoritmien käytön, joiden avulla pystytään luomaan tarkkoja analyysseja datasta sekä muun muassa tekemään ennustuksia sen perusteella. Luonnollisen kielen käsittelyä hyödynnetään lisätyssä analytiikassa esimerkiksi keskusteluanalyysin avulla, joka antaa käyttäjälle mahdollisuuden ”kysyä dataalta kysymyksiä”. Generatiivisen tekoälyn avulla lisätty analytiikka voi myös tuoda esille näkemyksiä sekä ratkaisuvaihtoehtoja, parhaassa tapauksessa kertoa datasta kaiken sen mikä on oleellista analyysiprosessissa. (Alghamdi & Al-Baity 2022; Rana ym. 2022.) Tiivistettynä lisätyn analytiikan avulla analyytikot sekä kansalaisdatatieteilijät voivat rakentaa entistä personoidumpia datamalleja sekä visualisointeja samalla tehostaen mallintamisen tarkkuutta saavuttaen yksinkertaisia oivalluksia datan pohjalta (Benke & Benke 2018; Prat 2019).

3 Lisätty analytiikka liiketoiminnassa

Tässä luvussa esitellään tarkemmin lisätyn analytiikan sekä tekoälysovelluksien tuomia muutoksia analytiikkaan. Jotta tekoälyn tuomat hyödyt analytiikalle voidaan ymmärtää, on hyödyllistä tarkastella prosessia ns. liiketoiminta-analytiikkasyklin (engl. business analytics cycle) näkökulmasta. Tässä luvussa esitellään tarkemmin liiketoiminta-analytiikkasykli tai yksinkertaisemmin analytiikkasykli ja sen eri vaiheet. Analytiikkasyklin eri vaiheiden esittelyn jälkeen esitellään yksityiskohtaisesti lisätyn analytiikan sekä tekoälysovellusten mahdollistamia muutoksia analytiikkasyklin eri vaiheissa, jotta saamme kattavan kuvan siitä, mitä tekoälyn avulla voidaan saavuttaa analytiikan parissa. Tämän luvun lopuksi yhdistetään tutkielman keskeiset aihepiirit ja esitellään lisättyä analytiikkaa päätöksenteon sekä liiketoiminnan kontekstissa.

3.1 Liiketoiminta-analytiikkasykli

Pratin (2019) mukaan analytiikkasyklin vaiheista on esitetty monenlaisia versioita. Chenin ym. (2012) mukaan liiketoiminta-analytiikkasykliin kuuluu erityisesti yrityksen tietoarkkitehtuuri, tekoälysovellukset, prosessin eri vaiheissa vaikuttavat henkilöt sekä päätöksentekijät ja erityisesti data, joka nähdään koko prosessin mahdollistavana tekijänä. Liitteenä oleva havainnollistus pohjautuu muun muassa Storeyn ja Songin (2017) malliin.



Kuvio 2. Liiketoiminta-analytiikkasykli, (engl. business analytics cycle), Storey & Song (2017) muokattu.

Storeyn ja Songin (2017) esittelemään malliin perustuva havainnollistus liiketoiminta-analytiikkasykli alkaa vaiheesta 1. Liiketoimintaongelman ja sen tuomien mahdollisuuden tunnistaminen. Tässä vaiheessa olennaista on ratkaistavan ongelman sekä massadatan liiketoiminnalle tuomien mahdollisuuksien tunnistaminen analytiikan avulla (Barton & Court 2018). Vaiheessa 2. datan valmistelu keskitytään tiedon profilointiin sekä muokkaamiseen/mallintamiseen. Analytiikkasyklin 3. Vaiheessa keskitytään tiedon hankintaan, analysointiin. Tässä vaiheessa rakennetaan datamalleja ja tehdään myös hankitun tiedon arviointia. Vaiheessa 4. Mallien käyttöönotto rakennetut mallit otetaan käyttöön esimerkiksi tuotantosovelluksissa. Vaiheessa 5. Päätöksenteko tehdään päätös kaiken aikaansaadun perusteella. Seuraavaksi vaiheessa 6. Toiminta tehtyjen päätösten perusteella päätöksen perusteella tehdyt toimenpiteet suoritetaan ja viimeisessä vaiheessa 7. Seuranta ja arviointi tehtyjen päätösten perusteella tehtyjen toimien suoritusta seurataan, arvioidaan ja toimintaa muokataan suoriutumisen perusteella.

Storeyn ja Songin (2017) esittelemään ideaan perustuva malli on vain yksi havainnollistus analytiikkasyklistä ja prosessista, joka vaihtelee laajasti riippuen organisaatiosta sekä analyysin kontekstista. Tämä 7-vaiheinen prosessi myötäilee kuitenkin suurelta osin prosessin rakennetta, joka on käytössä yrityksissä laajalti (Prat 2019). Nelsonin (2018) mukaan liiketoiminta-analytiikkasykliin liittyen on olennaista nähdä se jatkuvana toimintana sen sijaan, että sitä kohdeltaisiin suoraviivaisena prosessina, joka suoritetaan tiettyjä ennalta määrättyjä kaavoja noudattaen. Nelson (2018) myös toteaa, että analytiikkaan liittyen yrityksissä tulisi panostaa vakiintuneiden toimintatapojen, prosessien ja selkeiden analytiikkaa tukevien johtamismallien luomiseen. Tällöin prosessista voidaan hyötyä enemmän, kuin jos toiminta olisi sattumanvaraista ja rakenteetonta. Seuraavaksi tarkastelemme analytiikkasykliä lisätyn analytiikan näkökulmasta vaiheittain, jotta saamme kattavan ymmärryksen tekoälyn eri osa-alueiden mahdollistamien sovellusten tuomista hyödyistä liiketoiminta-analytiikkasyklille.

3.2 Tekoäly analytiikkasyklin eri vaiheissa

Tässä alaluvussa esitellään tekoälysovelluksien yleisellä tasolla tuomat mahdollisuudet ja muutokset perinteiseen analytiikkasykliin. Alghamdin ja Al-Baityn (2022) mukaan tekoälysovelluksien vaikutus syklin eri vaiheisiin vaihtelee merkittävästi: esimerkiksi monilla alustoilla tekoälyn tekemät ”valmiit” visualisoinnit ovat yleisesti hyvin edistyneitä samaan aikaan, kun alustojen luonnollisen kielen käsittelyä sekä generatiivista tekoäly hyödyntävät laajennukset ovat vielä paikoin alkeellisia. Taulukko 1. Tekoälysovellukset analytiikkasyklin eri vaiheissa esittelee pääpiirteittäin tekoälyn mahdollistaman muutoksen vaiheittain analytiikkasyklissä. Tässä esitetty malli pohjautuu muun muassa Pratin (2019) esittelemään malliin.

Taulukko 1 Tekoälysovellukset analytiikkasyklin eri vaiheissa. (Prat 2019 Muokattu).

Analytiikkasyklin vaihe	Tekoälysovellus
1. Liiketoimintaongelman- ja sen tuomien mahdollisuuksien tunnistaminen	- Ei varsinaista tekoälysovellusta. Voidaan kuitenkin hyödyntää esim. historiallista dataa tekoälyn avulla
2. Datan valmistelu (profilointi- ja mallinnus)	- Profilointi: Automatisoitu datan laadun määrittäminen - Muokkaus: Datan ”siivous”, uudelleenjärjestely, yhdistely tekoälyn avulla
3. Datan analysointi	- Löydösvaihe: visualisointiehdotukset ja parannukset, käyttäjän opastus löydöksiin liittyen, datan mahdollisuuksien tarkastelu NLP:n keinoilla (NLU, NLG) - Mallinnus: Mallin ominaisuuksien suunnittelu
4. Mallien käyttöönotto	- Välitön käyttöönotto ja implementointi osaksi tarvittavia järjestelmiä automaattisesti
5. Päätöksenteko	- Mahdollisuus automatisoida: Tekoäly voi tukea/toteuttaa lopullisen päätöksen esimerkiksi NLG:n kautta
6. Toiminta tehtyjen päätösten perusteella	- Mahdollisuus automatisoida: Tekoälysovelluksien avulla järjestelmä voi toimia tehtyjen päätösten mukaan osittain/kokonaan esimerkiksi tiettyyn järjestelmään tehtävien muutosten osalta
7. Seuranta ja arviointi	- Tekoälyn avulla datamalleja voidaan muokata dynaamisesti ja automaattisesti seurannassa ja arvioinnissa esille tulleiden ilmiöiden perusteella

Pratin (2019) mukaan yleisesti sanottuna analytiikkasyklin liiketoimintaongelman ja sen tuomien mahdollisuuksien tunnistaminen -vaiheessa ei ole suoraa tekoälysovellusta hyödynnettäväksi. Vaiheessa on kuitenkin mahdollista hyödyntää liiketoimintatiedon hallinta/tekoälyvälineitä esimerkiksi historiallisten havaintojen kautta ja ongelman tai mahdollisuuden tunnistaminen voi joskus jopa onnistua tällä tavalla. Tällöin esimerkiksi asiakasdatan avulla on mahdollista tunnistaa käsillä oleva ongelma sekä sen tuomat mahdollisuudet, joihin analytiikalla pyritään vastaamaan.

Datan valmistelu voi joskus viedä ajallisesti jopa suurimman osan analytiikkasykliin käytetystä ajasta (Alghamdi & Al-Baity 2022). Tämän vaiheen automatisoinnilla voidaan siis saavuttaa suurta hyötyä tehostamalla analyysiprosessia. Erilaisten markkinoilla olevien tekoälysovellusten avulla datan valmistelua voidaan automatisoida välineillä,

jotka pystyvät esimerkiksi tulkitsemaan lauserakenteita ja merkityksiä tekoälyn avulla eri muodossa olevasta datasta. Kakatkarin ym. (2020) mukaan tämä tarkoittaa käytännössä sitä, että tekoälyn avulla voidaan tehokkaasti suorittaa esimerkiksi tiedonlouhintaa eri tietokannoista, joissa oleva data on sekä strukturoitua, että strukturoimatonta. Tekoälysovellusten kuten Trifacta Wranglerin avulla voidaan myös osittain automatisoida datan profilointi- ja muokkaustoimenpiteitä esimerkiksi turhien- ja päällekkäisarvojen poistamisen myötä. Näillä menetelmillä voidaan automatisoida suuri osa datan valmistelusta, joka on perinteisin menetelmin työlästä ja aikaa vievää (Prat 2019).

Datan analysointivaiheessa esimerkiksi Tableau-nimisellä liiketoimintatiedonhallinta-työkalulla voidaan automatisoida löydösvaihetta erityisesti analyysia tukevien visualisointiehdotusten sekä parannuksien myötä. Tämä tapahtuu algoritmien sekä tilastollisten mallien avulla (Ashley 2019.) Pratin (2019) mukaan samaa tekoälyn mahdollistamaa tekniikkaa hyödynnetään myös monien muiden palveluntarjoajien tekoälysovelluksissa. Knightin (2017) mukaan tekoälyä voidaan hyödyntää myös mallintamisessa datan analysointivaiheessa. Mallinnuksessa on mahdollista koneoppimisalgoritmien avulla kokeilla jopa tuhansia erilaisia malleja, joissa on eri ominaisuuksia hyvin nopeasti tehostaen analysointivaihetta kokonaisvaltaisesti.

Mallien käyttöönottovaiheessa tekoälyä hyödyntävien välineiden, kuten Alteryxin Promoten avulla mallintamisen ja käyttöönoton välisiä ongelmia voidaan vähentää. Tekoälyavusteisen automatiikan avulla on mahdollista automatisoida täysin tai osittain prosessi mallintamisen sekä käyttöönoton välillä. Tämä tapahtuu ilman suurta tarvetta uudelleenkoodaamiselle järjestelmien välillä ja koneoppimisalgoritmien avulla käyttöönotetut mallit voidaan tarvittaessa päivittää uudella datalla helposti. (Kobielus 2017.)

Pratin (2019) mukaan ainakin toistaiseksi suorat tekoälysovellukset päätöksentekovaiheessa sekä sen jälkeen puuttuvat. On kuitenkin osittain mahdollista automatisoida myös päätöksentekoprosessi sekä jälkitoimet varsinaisiin toimiin sekä seurantaan ja arviointiin liittyen. Tällöin esimerkiksi generatiivisen tekoälyn avulla on mahdollista ”ulkoistaa” päätöksenteko järjestelmälle sekä antaa sille valtuudet muokata toimintaa päätöksen sekä tulevaisuudessa syntyvien tulosten perusteella. Albrechtin ym. (2021) mukaan päätöksentekoprosessia on kuitenkin mahdollista tukea monin paikoin

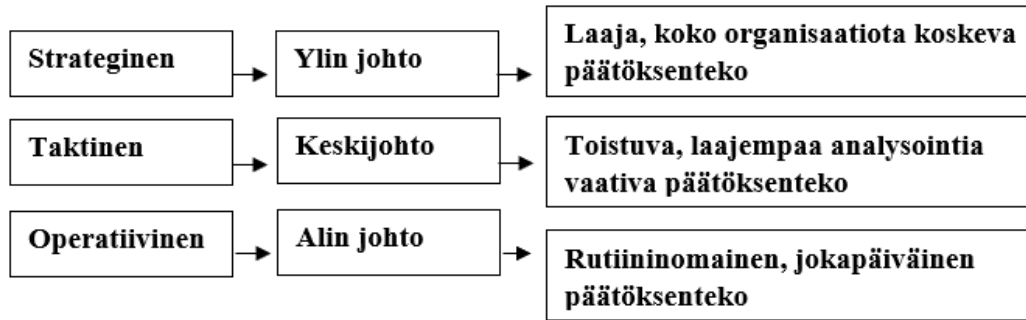
tekoälyn avulla esimerkiksi ennustavien koneoppimisalgoritmien avulla, jolloin päätöksentekoa voidaan tehostaa.

Kaiken kaikkiaan voidaan todeta, että lisätyn analytiikan sekä erilaisten tekoälysovellusten avulla on mahdollista muuttaa ja automatisoida liiketoiminta-analytiikkaprosessia ja täten parhaassa tapauksessa tehostaa toimintaa ja saavuttaa suurempia hyötyjä, kun manuaalista työtä tekevät ihmiset voidaan uudelleen sijoittaa prosessin vaiheisiin, jotka tuottavat enemmän liiketoiminnallista hyötyä sekä vaativat ainakin vielä toistaiseksi enemmän ihmistyötä. (Prat 2019; Alghamdi & Al-Baity 2022.)

3.3 Päätöksenteon kehittäminen lisätyn analytiikan avulla

Päätöksenteko yrityksissä voidaan jakaa yleisesti kolmeen osaan: strateginen, taktinen ja operatiivinen päätöksenteko. Strategista päätöksentekoa tehdään koko organisaation tasolla. Strategiset päätökset koskevat yleisiä, monimutkaisia asioita, joilla on vaikutus koko organisaation toimintaan. Strategiset päätökset vaativat yleisesti paljon analyysia sekä eri vaihtoehtojen arviointia. Näitä päätöksiä tekevät yleisesti korkeimman tason, ylimmän johdon päätöksentekijät. Esimerkkinä strategisesta päätöksestä voidaan pitää uuden markkina-alueen valitsemista tai tuote tai palveluvalikoiman muutosta. (Harrington & Ottenbacher 2009.)

Harringtonin ja Ottenbacherin (2009) mukaan taktinen päätöksenteko sijoittuu strategisen- ja operatiivisen päätöksenteon väliin. Heidän mukaansa taktinen päätöksenteko keskittyy siis toistuvien, tuttujen tilanteiden ratkomiseen, jotka vaativat enemmän arviointia ja analysointia, kuin operatiiviset päätökset. Taktiset päätökset kuuluvat yleisesti keskijohdon työnkuvaan. Edwarsin ym. (2000) mukaan operatiivinen päätöksenteko tarkoittaa ”alimmalla” tasolla tehtäviä rutiininomaisia päätöksiä. Operatiivinen päätöksenteko koskee siis tunnettuja, toistuvia ilmiöitä kuten varaston tai henkilöstönhallintaa. Kuviossa 3 ”Päätöksenteko organisaatiossa” havainnollistetaan päätöksenteon jakoa strategiseen, taktiseen ja operatiiviseen organisaatiokontekstissa.



Kuvio 3. Päätöksenteko organisaatiossa, Harrington & Ottenbacher (2019) muokattu.

Päätöksenteko yrityksissä voidaan jaotella myös strukturoituun, osittain strukturoituun ja strukturoimattomaan päätöksentekoon. Tässä tutkielmassa tarkastellaan lisätyn analytiikan tuomia muutoksia päätöksentekoon jakamalla se strategiseen, taktiseen ja operatiiviseen päätöksentekoon tutkielman laajuuden ja rajoitusten vuoksi.

Pratin (2019) mukaan ei päätöksentekoa voida ainakaan vielä toistaiseksi täysin automatisoida tekoälyn avulla. Edwardsin ym. (2000) mukaan tekoälyä voidaan käyttää päätöksentekijän tukena tai päätöksentekijä voidaan korvata täysin tietyin rajoituksin esimerkiksi operatiivisen tason päätöksenteossa. Taktisen ja etenkin strategisen tason päätöksenteossa tekoälyn hyödyntäminen vaikeutuu muun muassa päätöksenteon kohteena olevien asioiden monimutkaisuuden sekä laajemman analyysin tarpeen vuoksi (Duan 2019).

Lisätty analytiikka päätöksenteon kontekstissa voidaan nähdä hyödyllisenä tekijänä, jonka avulla voidaan parhaassa tapauksessa päätöksentekoprosessin tehostamisen lisäksi saavuttaa liiketoiminnallista hyötyä (Yin & Fernandez 2020; Alghamdi & Al-Baity 2022). Albrecht ym. (2021) esittää, että lisätty analytiikka ehostaa yritysten sisäistä päätöksentekoa ja päätöksentekoprosesseja tekemällä näistä ainakin nopeampia ja älykkäämpiä. Yritykset voivat hyötyä lisätystä analytiikasta erityisesti koneoppimisalgoritmien avulla, jolloin esimerkiksi historiallisen datan perusteella tehtyjen ennusteiden avulla saavutetaan hyötyä päätöksenteon kontekstissa (Chen ym. 2012). Chenin ym. (2012) mukaan ennusteet ja mallit vähentävät myös liiketoimintaan kohdistuvaa riskiä, koska niiden avulla pystytään ottamaan huomioon ja valmistautumaan erilaisiin tilanteisiin. Voidaan siis todeta, että lisätyn analytiikan avulla yritykset voivat

saavuttaa liiketoiminnallista hyötyä sekä kilpailuetua tarkemman ja nopeamman päätöksentekoprosessin myötä. Tämän myötä on myös mahdollista ohjata yrityksen resursseja, kuten työvoimaa analytiikkaprosessin tuottavampiin osiin, joissa tekoälyä ei ainakaan toistaiseksi voida hyödyntää niin laaja-alaisesti, jolloin toimintaa saadaan optimoitua kokonaisvaltaisesti. (Chen ym. 2017.)

Edwards ym. (2000) esittää, että tekoälyä hyödyntäen on kannattavaa automatisoida päätöksentekoa erityisesti operatiivisella ja taktisella tasolla. Heidän mukaansa erilaisten tekoälysovellusten käyttö rajoittuu merkittävästi siirryttäessä taktiselta tasolta strategiselle tasolle. On kuitenkin huomioitavaa, että Edwardsin ym. (2000) tutkimus on julkaistu jo yli 20 vuotta sitten. Tutkimusaukon ja varteenotettavien julkaisujen puutetta alalla voi pohtia, sillä esimerkiksi Duan ym. (2019) perustaa oman tutkimuksensa pitkälti Edwardsin ym. (2000) havaintoihin.

Duanin ym. (2019) mukaan tekoälyn puutokset liittyen päätöksentekoprosessin täysautomaatioon voidaan nähdä myös positiivisena asiana. Heidän mukaansa lisätty analytiikka ja tekoäly tulisi nähdä ennemmin päätöksentekoa tukevana välineenä tai työkaluna. Tällöin tekoälyn avulla on mahdollista tukea päätöksenteon suorittavaa ihmistä niillä alueilla, joissa esimerkiksi ihmisen kyvykkyydet tai resurssit, kuten aika ovat puutteellisia näin lisäten päätöksentekijän kykyjä tehdä tarkempia ja parempia päätöksiä. Duanin ym. (2019) mukaan näin toimiessa yrityksen työntekijöillä on mahdollisuus tehdä parempia päätöksiä nopeammin, joka mahdollistaa myös päätöksentekoprosessiin uponneiden kustannusten vähentämisen ja resurssien uudelleenohjaamisen. Näin toimimalla on mahdollisuus tukea lopullisen päätöksen tekevää ihmistä niillä alueilla, joilla resurssit eivät riitä. Väitettä siitä, että tekoäly ja lisätty analytiikka tulisi nähdä täyden automaation sijaan ennemmin päätöksentekoa tukevana välineenä tai työkaluna tukee myös Wilsonin ja Daughertyn (2018) väite siitä, että yritykset, jotka korvaavat tekoälyn avulla työntekijöitä kokonaan saavuttavat näin tekemällä vain lyhytaikaisia hyötyjä liiketoiminnan tuottavuudelle.

Duanin ym. (2019) mukaan analytiikassa tekoäly koetaan yleisesti työ- ja apuvälineenä, jonka tarkoitus on tukea lopullisen päätöksen tekevää ihmistä. Tämä tapahtuu erilaisten tekoälysovellusten avulla tuotettujen havaintojen ja tulosten myötä. Tämä näkökulma on tämän tutkielman kannalta oivallinen, sillä tutkimuskysymyksellä ”miten lisättyä analytiikkaa voidaan hyödyntää liiketoiminnan apuna?” pyritään vastaamaan

kysymykseen hyödyntämisen näkökulmasta. Tällöin voidaan sanoa, että analytiikkaprosessin tai päätöksenteon täysi automaatio ei ole tämän tutkielman kannalta olennaista vaan tarkoituksena on selvittää lisätyn analytiikan tuomia hyötyjä liiketoiminnalle.

Barton ja Court (2012) esittävät myös, että lisätyn analytiikan roolin päätöksenteossa tulisi olla varsinaista päätöksentekijää tukeva. Tarkemmin, heidän mukaansa lisätyn analytiikan välineiden käytön tulisi tapahtua mahdollisimman lähellä tehtävää päätöstä. Tämä tarkoittaa myös sitä, että lisätyn analytiikan välineiden tulisi olla lopullisen päätöksentekijän käytettävissä eikä näiden hyödyntämisen tulisi tapahtua esimerkiksi strategisella päätöksenteon tasolla, jos lopullinen päätös tehdään operatiivisella päätöksenteon tasolla. Edwards ym. (2000) esittävät kuitenkin, että vaikka lisättyä analytiikkaa voidaan hyödyntää monipuolisesti etenkin operatiivisella sekä taktisella päätöksenteon tasolla, ei se aina säästä sitä hyödyntävän henkilön aikaa. Tämä johtuu siitä, että useimmiten hyödyntävän henkilön, tässä tapauksessa päätöksentekijän tulee tehdä päätös loppujen lopuksi itse ja ylimääräisen tukevan välineen käyttö voi tuhata aikaa, mikäli tehtävä päätös on yksinkertainen.

3.4 Lisätyn analytiikan hyödyntäminen liiketoiminnassa

Lisätyn analytiikan hyödyntäminen liiketoiminnassa antaa yritykselle mahdollisuuden saavuttaa kilpailuetua markkinoilla, joissa pienenkin edun saaminen voi olla merkittävää (Alghamdi & Al-Baity 2022). Tässä aluvuossa esitetään viitekehys, joka kuvaa lisätyn analytiikan hyödyntämistä liiketoiminnassa perustuen kirjallisuuskatsauksessa esiteltyihin asioihin.

Lisätyn analytiikan tehokas hyödyntäminen vaatii yrityksiltä tietynlaista osaamista, ymmärrystä ja valmiuksia. Tämä tarkoittaa käytännössä eri työkalujen ja välineiden läpikotaista tuntemusta ja myös niiden merkityksen käsitystä koko liiketoiminnan mittakaavassa. (Watson 2014; Watson 2019.)

Cordoban (2014) mukaan lisätyn analytiikan hyödyntäminen vaatii myös liiketoiminta-analytiikkasyklin kokonaisvaltaista ymmärrystä jatkuvana toimintana yksittäisten tarpeiden täyttämisen sijaan. Lisätyn analytiikan hyödyntäminen oikealla tavalla tehostaa yrityksen analyysiprosessia sekä päätöksentekoa (Alghamdi & Al-Baity 2022). Toteutuakseen tämä kuitenkin vaatii tiettyjä lähtökohtia, kuten riittävää datamäärää.

Bhageshpurin (2019) mukaan ”data on uusi öljy”, tämä tarkoittaa sitä, että data on viime vuosien aikana saavuttanut saman merkittävyyden tason öljyn kanssa ja nyt nämä kaksi ovat maailman tärkeimmät luonnonvarat. Tämä realisoituu myös analytiikassa, sillä massadatan aikakaudella yritysten tehokas liiketoiminta-analytiikkaprosessi vaatii toimiakseen optimaalisesti riittävää datamäärää, jonka ominaisuudet otetaan tehokkaasti huomioon.

Benken & Benken (2018) mukaan lisätyn analytiikan hyödyntäminen vaatii yrityksiltä myös tietynlaista tietoarkkitehtuuria. Watson (2014) korostaa osaavan ja tietynlaisilla kyvyillä varustetun henkilöstön merkitystä tekoälyn hyödyntämisessä analytiikassa. Tämän tutkielman laajuuden vuoksi näihin ei kuitenkaan ole paneuduttu tarkemmin. Voidaan kuitenkin todeta, että optimaalisessa tilanteessa tekoälyä hyödyntävä lisätty analytiikka vaatii riittävän monipuolisen, tehokkaan ja toimivan tietoarkkitehtuurin (Benke & Benke 2018). Henkilöstön osalta muun muassa Chenin ym. (2012) mukaan analytiikan parissa toimivilla henkilöillä tulisi olla tietynlaiset valmiudet, jotta monipuolisia välineitä kuten lisättyä analytiikkaa voidaan hyödyntää. Näitä ominaisuuksia ovat muun muassa sosiaaliset taidot sekä riittävä tekninen osaaminen. Käytännössä henkilöstöltä vaaditaan siis ainakin kykyä toimia ja kommunikoida muiden ihmisten kanssa sekä tietynlaista ymmärrystä ja valmiuksia työskennellä analytiikan parissa.

Kuten luvussa 3.2 nähtiin, voidaan lisättyä analytiikkaa hyödyntämällä saavuttaa nopeampi ja tehokkaampi liiketoiminta-analytiikkaprosessi suuremmasta ja monipuolisemmasta datamäärästä. Lisäksi lisätyn analytiikan avulla tuotetuiden mallien avulla voidaan vähentää liiketoimintaan kohdistuvaa riskiä sekä ennakoida erilaisia tilanteita joustavamman analytiikan avulla. Lisätty analytiikka myös vähentää inhimillisiä virheitä automatisoimalla työvaiheita, joissa riski inhimillisille virheille on korkea (Chen ym. 2012).

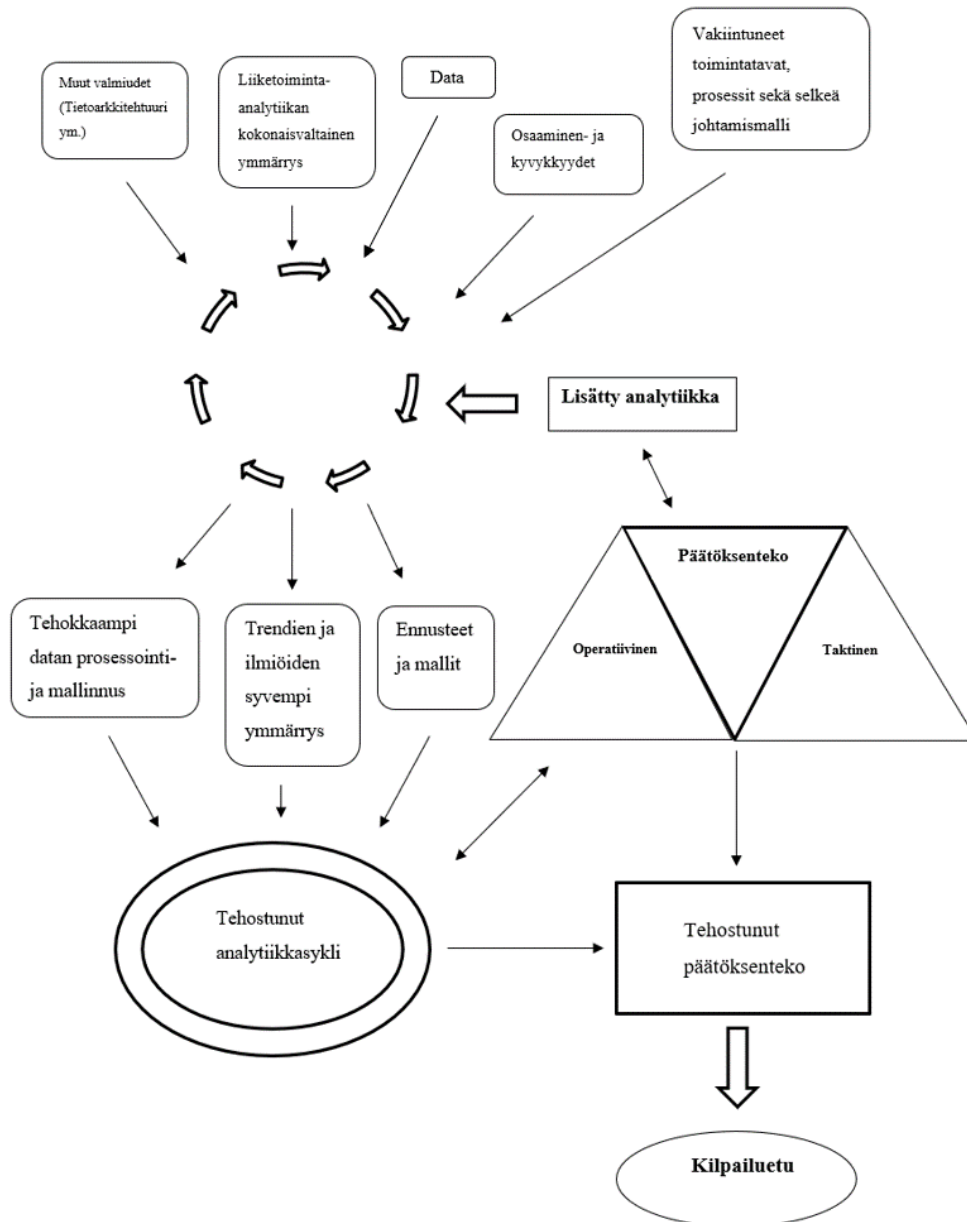
Lisättyä analytiikkaa voidaan hyödyntää liiketoiminnassa monipuolisesti. Hyödyntäminen tapahtuu usein yritysten päätöksenteon kontekstissa kuten luvussa 3.3 nähtiin. Yleisesti lisätyn analytiikan avulla voidaan tehdä yrityksen päätöksenteosta tehokkaampaa muokkaamalla päätöksentekoprosessia nopeammaksi ja älykkäämmäksi. Lisätyn analytiikan hyödyntäminen antaa päätöksentekijälle mahdollisuuden reagoida liiketoimintaympäristön muuttuviin tilanteisiin joustavammin myös epävarmoissa

tilanteissa lisätyn analytiikan metodien tuodessa analytiikkaan syvempää ja tarkempaa analyysia myös vaihtoehtoisista tilanteista. (Duan ym. 2019; Albercht ym. 2021; Alghamdi & Al-Baity 2022.)

Hyödyntäessä lisättyä analytiikkaa päätöksentekoprosessissa on kuitenkin huomioitava siihen liittyvät rajoitukset. Edwardsin ym. (2000) mukaan lisätyn analytiikan hyödyntäminen on tehokasta erityisesti operatiivisen ja taktisen tason päätöksenteossa. Tämän seurauksena ainakin toistaiseksi lisättyä analytiikan hyödyntäminen on haastavampaa monimutkaisemmissa, koko organisaation toimintaa koskevissa strategisen päätöksenteontason päätöksissä.

Lisätty analytiikka tulee nähdä ensisijaisesti päätöksentekoa tukevana välineenä- ja työkaluna eikä sillä tulisi pyrkiä täysin automatisoimaan päätöksentekoprosessia (Barton & Court, 2018). Duanin ym. (2019) mukaan on lisäksi olennaista tunnistaa ne tilanteet, joissa tekoälyä hyödyntävän lisätyn analytiikan käyttö on hyödyllistä, sillä se ei aina säästä päätöksentekijän aikaa, jos esimerkiksi päätöksentekoprosessi on kovin yksinkertainen. Tässä kontekstissa on myös hyvä huomioida, että lisätyn analytiikan välineiden tulisi olla mahdollisuuksien mukaan viimeisen päätöksen tekevän ihmisen käytettävissä, jotta niistä saatava hyöty voidaan maksimoida.

Lisätyn analytiikan avulla voidaan myös säästää yrityksen resursseja, sillä sitä hyödyntämällä on esimerkiksi mahdollista automatisoida analytiikkaprosessia niiltä osin, jotka perinteisesti kuluttavat yrityksen resursseja ja uudelleenohjata näitä resursseja analytiikkaprosessin tuottavampiin osiin (Alghamdi & Al-Baity 2022). Parhaimmillaan lisätyn analytiikan hyödyntäminen liiketoiminnassa näkyy yrityksen työntekijöiden parantuneena kykyinä toimia osana liiketoiminta-analytiikkaprosessia sekä toiminnan- ja päätöksenteon tehostumisena. Viitekehys, joka kuvaa lisätyn analytiikan hyödyntämistä liiketoiminnassa on hahmoteltu kuvioon 4. ”Lisätyn analytiikan hyödyntäminen liiketoiminnassa”.



Kuvio 4. Lisätyn analytiikan hyödyntäminen liiketoiminnassa. Edwards ym. (2000), Chen ym. (2012), Cordoba (2014), Barton & Court (2018), Benke & Benke (2018), Duan ym. (2019), Albrecht ym. (2021), Alghamdi & Al-Baity (2022), muokattu.

4 Yhteenveto ja johtopäätökset

Tutkielmassa tarkasteltiin, miten yritykset voivat hyödyntää tekoälyä ja sitä hyödyntävää lisättyä analytiikkaa liiketoiminnassa. Tarkemmin katsottuna kirjallisuuskatsauksen avulla selvitettiin miten yritykset voivat lisätyn analytiikan avulla tehostaa liiketoiminta-analytiikkaprosessia sekä päätöksentekoa ja tämän myötä saavuttaa kilpailuetua. Seuraavaksi perehdytään tarkemmin kirjallisuuskatsauksen avulla saatuihin johtopäätöksiin tutkimuskysymysten kautta sekä pohditaan hieman tutkielman rajoituksia sekä potentiaalisia jatkotutkimusmahdollisuuksia.

Tutkielmassa esiteltiin lisätty analytiikka sekä siihen olennaisesti liittyvät käsitteet. Tämän jälkeen perehdyttiin tarkemmin liiketoiminta-analytiikkasykliin sekä lisätyn analytiikan hyödyntämiin tekoälysovelluksiin, jotka vaikuttavat tässä ”tehostuneessa” liiketoiminta-analytiikkasyklissä. Tämän jälkeen käsiteltiin päätöksentekoa lisätyn analytiikan kontekstissa eri organisaation päätöksentekotasolla ja organisaatioissa yleisesti. Lopuksi esiteltiin viitekehys, jonka mukaan yritykset voivat hyödyntää lisättyä analytiikkaa liiketoiminnassa. Seuraavaksi käydään tutkielman rakenne tutkimuskysymyksiensä avulla läpi.

Tutkielmassa perehdyttiin aluksi lisättyyn analytiikkaan sekä siihen olennaisesti liittyviin käsitteisiin ja vastattiin alatutkimuskysymykseen 1. a ”mitä on lisätty analytiikka?”. Lisätyn analytiikan yhteydessä esiteltiin liiketoimintatiedon hallinta, tekoäly ja luonnollisen kielen käsittely. Liiketoimintatiedon hallinta tarkoittaa käytännössä teknologioita, tekniikoita, järjestelmiä, toimintatapoja ja metodiikkoja, joiden avulla kyetään analysoimaan sekä ymmärtämään merkittävää liiketoimintatietoa ja tekemään sen pohjalta liiketoiminnan kannalta tärkeitä päätöksiä oikealla tavalla ja oikeaan aikaan. Tutkielmassa havaittiin myös, että tekoälylle ei ole yksiselitteistä määritelmää mutta yleisesti voidaan kuitenkin sanoa, että tekoälyllä tarkoitetaan käytännössä tietojärjestelmiä, joilla on kyky tehdä päätelmiä sekä toimia tehtyjen päätösten perusteella ihmisten tai ihmisaivojen tavoin. Lisäksi tekoälyyn liittyen esiteltiin kone- ja syväoppimisen käsitteet.

Kun lisättyyn analytiikkaan olennaisesti liittyvät käsitteet olivat esitelty, perehdyttiin vielä tarkemmin lisättyyn analytiikkaan ja siihen, miten lisätty analytiikka hyödyntää edellä esiteltyjä käsitteitä toiminnassaan. Havaittiin, että lisätty analytiikka mahdollistaa

analytiikkaprosessin laaja-alaisen automaation ja se tarjoaa tekoälyn avulla nopeampaa ja tarkempaa tietoa päätöksenteon tueksi. Tämä tapahtuu pääasiassa koneoppimisen sekä luonnollisen kielen käsittelyn tekoälysovellusten kautta, joilla lisätty analytiikka mullistaa perinteisen liiketoiminta-analytiikan.

Tarkasteltaessa tutkimuskysymyksiä 1. miten lisättyä analytiikkaa voidaan hyödyntää liiketoiminnan apuna sekä 1. b ”miten lisättyä analytiikkaa voidaan hyödyntää päätöksenteon tukena” on hyödyllistä tarkastella yhdessä, sillä ne liittyvät toisiinsa olennaisesti. Tutkielman luku 3. ”Lisätty analytiikka liiketoiminnassa” käsitteli molempia aiheita yhdessä ja erikseen. Esiteltiin liiketoiminta-analytiikkasykli, jotta yrityksissä tehtävä analytiikkaprosessi, sekä sitä muokkaava lisätty analytiikka voitiin ymmärtää paremmin. Kirjallisuuskatsauksen perusteella havaittiin, että liiketoiminta-analytiikkasykli koostuu seitsemästä vaiheesta, joita ovat: liiketoimintaongelman tunnistaminen, datan valmistelu, datan analysointi, mallien käyttöönotto, päätöksenteko, toiminta tehtyjen päätösten perusteella sekä seuranta ja arviointi.

Liiketoiminta-analytiikkasyklin esittelyn jälkeen tarkasteltiin lisättyä analytiikkaa sekä sen tuomia muutoksia ja mahdollisuuksia analytiikkasyklin eri vaiheissa. Tutkielmassa havaittiin, että lisätyn analytiikan ja sen tuomien tekoälysovellusten avulla voidaan tehostaa ja tukea prosessia automatisoimalla esimerkiksi datan valmisteluprosessia, joka yleisesti vie suuren osana liiketoiminta-analytiikkasykliin käytetyistä resursseista. Opittiin myös, että lisätyn analytiikan avulla on mahdollista nopeuttaa prosessia esimerkiksi tekoälysovellusten tekemien visualisointiehtotusten sekä optimoitujen datamallien avulla. Mahdollisesti tärkeimpänä asiana tutkielman kannalta esiin nousi, että lisätyn analytiikan avulla on mahdollista tukea ja automatisoida päätöksentekoprosessia.

Tutkielman loppupuolella keskityttiin lisättyyn analytiikkaan ja päätöksentekoon. Kirjallisuuskatsauksen perusteella havaittiin, että organisaatioissa päätöksenteko jaetaan yleisesti strategiseen, taktiseen ja operatiiviseen päätöksentekoon. Tekoäly ja sitä hyödyntävä lisätty analytiikka voi automatisoida ja tukea päätöksentekoa erityisesti operatiivisella ja taktisella tasolla. Strategisen päätöksenteon tasolla lisätyn analytiikan hyödyntäminen on yleisesti haastavaa, päätöksenteon kohteina olevien asioiden ollessa monimutkaisempia. Havaittiin, että lisätty analytiikka tulisi nähdä myös ensisijaisesti päätöksentekoa tukevana välineenä, eikä pyrkiä prosessin täyteen automatisaatioon.

Tukivälineenä/työkaluna hyödynnettynä lisätty analytiikka voi parantaa päätöksentekijän kykyä tehdä tarkempia päätöksiä nopeammin.

Tehdyn kirjallisuuskatsauksen perusteella päädyttiin lopulta käsittelemään lisätyn analytiikan hyödyntämistä liiketoiminnassa. Tutkielmassa yhteen vedettiin aiemmin käsiteltyjä aiheita ja lyhyesti myös asioita, joita yrityksiltä vaaditaan, jotta lisättyä analytiikkaa voidaan hyödyntää liiketoiminnassa. Havaittiin, että lisätyn analytiikan tehokas hyödyntäminen vaatii yrityksiltä tietynlaista osaamista, ymmärrystä sekä valmiuksia, vakiintuneita toimintatapoja ja prosesseja sekä riittävää massadatan määrää. Lisäksi liiketoiminta-analytiikka tulisi nähdä jatkuvana prosessina sekä se tulisi ymmärtää kokonaisuutena, eikä vain yksittäisten vaiheiden suorittamisena. Näin tekemällä ja lisättyä analytiikkaa hyödyntämällä yritykset voivat prosessoida dataa tehokkaammin, ymmärtää sitä paremmin ja tehdä parempia ennusteita ja malleja. Tämä johtaa tehokkaampaan analytiikkasykliin ja sitä kautta tehokkaampaan päätöksentekoon erityisesti taktisella ja operatiivisella päätöksenteon tasolla johtaen parhaassa tapauksessa kilpailuedun saavuttamiseen kilpailluilla markkinoilla.

Johtopäätöksenä voidaan todeta, että tekoäly ja sitä hyödyntävä lisätty analytiikka voivat tarjota yrityksille merkittäviä etuja liiketoiminta-analytiikan suorittamisessa sekä päätöksenteossa. Lisätyn analytiikan avulla on mahdollista tehostaa prosesseja kokonaisvaltaisesti, nopeuttaa ja parantaa päätöksentekoa tukemalla päätöksentekijää erityisesti taktisella ja operatiivisella päätöksenteon tasolla. Lisätty analytiikka tulee nähdä ensisijaisesti päätöksentekoprosessia tukevana välineenä erityisesti komplekseissa päätöksentekotilanteissa. Saavuttaakseen kaiken tämän yrityksiltä vaaditaan kuitenkin tietynlaista valmiuksia, kuten tietotaitoa, vakiintuneita prosesseja sekä riittävää massadatan määrää.

Tutkielmassa keskityttiin päätöksentekijöiden näkökulmaan sekä lisätyn analytiikan hyödyntämiseen liiketoiminta-analytiikassa erityisesti päätöksenteon kontekstissa. Tutkielman laajuuden takia ei keskitytty lisätyn analytiikan hyödyntämiseen liittyviin mahdollistaviin tai rajoittaviin tekijöihin, vaikka niitä käsiteltiin pintapuolisesti.

Mahdolliset jatkotutkimusaiheet tutkielman pohjalta liittyvät olennaisesti lisätyn analytiikan hyödyntämiseen liiketoiminnassa. Tutkielma tarjoaa kattavan pohjan laajemmalle jatkotutkimukselle esimerkiksi pro gradu -tutkielmassa. Mahdollisia näkökulmia jatkotutkimukselle voisi olla esimerkiksi case-tutkimus, jossa lisätyn

analytiikan hyödyntämistä tarkastellaan esimerkiksi teollisuuden, tai jonkin muun alan yrityksessä. Tämän pohjalta olisi myös mahdollista suorittaa tutkimusta esimerkiksi lisätyn analytiikan hyödyntämisestä pienissä ja keskisuurissa yrityksissä. Tämänlainen tutkimus olisi luultavasti käytännöllisin suorittaa kvalitatiivisena tutkimuksena, mutta mahdollisuuksia myös kvantitatiivisen tutkimuksen suorittamiseen on olemassa.

Lähteet

- Al-Baity, H. H., & Alghamdi, N. A. (2022). Augmented Analytics Driven by AI: A Digital Transformation beyond Business Intelligence. *Sensors*, 22(20), Article 20. <https://doi.org/10.3390/s22208071>
- Alpar, P., & Schulz, M. (2016). Self-Service Business Intelligence. *Business & Information Systems Engineering*, 58(2), 151–155. <https://doi.org/10.1007/s12599-016-0424-6>
- Ashley, I. (2019). Automated Data Discovery in Tableau. *Visual BI Solutions*. <https://visualbi.com/blogs/tableau/automated-data-discovery-tableau/>, haettu 4.10.2023.
- Barton, D., & Court, D. (2012). Making Advanced Analytics Work For You. *Harvard Business Review*, 90(10), 78–128. <https://hbr.org/2012/10/making-advanced-analytics-work-for-you>, haettu 04.11.2023.
- Benke, G., & Benke, K. (2018). Artificial Intelligence and Big Data in Public Health. *International Journal of Environmental Research and Public Health*, 15(12), Article 12. <https://doi.org/10.3390/ijerph15122796>
- Bhageshpur, K. (2019). Data Is The New Oil -- And That's A Good Thing. *Forbes*. <https://www.forbes.com/sites/forbestechcouncil/2019/11/15/data-is-the-new-oil-and-thats-a-good-thing/>, haettu 18.10.2023.
- Bulusu, L., & Abellera, R. (2020). Introduction-Three Generations of BI. In *AI Meets BI: Artificial Intelligence and Business Intelligence* (1st ed., pp. 3–7). Boca Raton, FL, USA: Auerbach Publications; London, UK; New York, NY, USA: CRC Press.
- Chaudhuri, S., & Dayal, U. (1997). An overview of data warehousing and OLAP technology. *ACM SIGMOD Record*, 26(1). <https://dl.acm.org/doi/abs/10.1145/248603.248616>
- Chen, H., Chiang, R. H. L., & Storey, V. C. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, 36(4), 1165–88. <https://doi.org/10.2307/41703503>
- Chen, Y., Wang, Y., Nevo, S., Benitez, J., & Kou, G. (2017). Improving strategic flexibility with information technologies: insights for firm performance in an emerging economy. *Journal of Information Technology*, 32(1), 10–25. <https://doi.org/10.1057/jit.2015.26>

- Cordoba, A. (2014). *Understanding the Predictive Analytics Lifecycle*. John Wiley & Sons, Incorporated.
- 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>
- Fanni, S. C., Febi, M., Aghakhanyan, G., & Neri, E. (2023). Natural Language Processing. In *Introduction to Artificial Intelligence. Imaging Informatics for Healthcare Professionals* (pp. 83–104). Springer. https://doi.org/10.1007/978-3-031-25928-9_5
- Gartner. (2017). Augmented analytics is the future of data and analytics (overview of the report in Rita Sallam's public article). <https://blogs.gartner.com/rita-sallam/2017/07/31/just-buying-into-modern-bi-and-analytics-get-ready-for-augmented-analytics-the-next-wave-of-market-disruption/>, haettu 29.9.2023.
- Harrington, R. J., & Ottenbacher, M. C. (2009). Decision-Making Tactics and Contextual Features: Strategic, Tactical and Operational Implications. *International Journal of Hospitality & Tourism Administration*, 10(1), 25–43.
<https://doi.org/10.1080/15256480802557259>
- Kasneji, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., ... & Kasneji, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- Nti, K., Quarcoo, J. A., Aning, J., & Fosu, G. K. (2021). A mini-review of machine learning in big data analytics: Applications, challenges, and prospects. *Big Data Mining and Analytics*, 5(2), 81–97.
<https://doi.org/10.26599/BDMA.2021.9020028>
- Nelson, G. S. (2018). *The Analytics Lifecycle Toolkit: A Practical Guide for an Effective Analytics Capability*. John Wiley & Sons.
- Prat, N. (2019). Augmented Analytics. *Business & Information Systems Engineering*, 61(3), 375–380. <https://doi.org/10.1007/s12599-019-00589-0>
- Pribisalić, M., Jugo, I., & Martinčić-Ipšić, S. (2019). Selecting a Business Intelligence Solution that is Fit for Business Requirements. *BLED 2019 Proceedings*. <https://aisel.aisnet.org/bled2019/37>, haettu 2.10.23.

- Rana, N. P., Chatterjee, S., Dwivedi, Y. K., & Akter, S. (2022). Understanding dark side of artificial intelligence (AI) integrated business analytics: assessing firm's operational inefficiency and competitiveness. *European Journal of Information Systems*, 31(3), 364–387. <https://doi.org/10.1080/0960085X.2021.1955628>
- Richardson, J., Sallam, R., Schlegel, K., Kronz, A., & Sun, J. (2020). Magic Quadrant for Analytics and Business Intelligence Platforms. Gartner ID G00386610. <https://bpmtraining.net/wp-content/uploads/2020/10/gartner-magic-quadrant-for-analytics-and-business-intelligence-platforms-feb-2020.pdf>, haettu 5.10.2023.
- Ruby, M. (2023, February 16). How ChatGPT Works: The Models Behind The Bot. Medium. <https://towardsdatascience.com/how-chatgptworks-the-models-behind-the-bot-1ce5fca96286>, haettu 14.10.2023.
- Sallam, R. (2019). How Augmented Analytics Will Transform Your Organization: A Gartner Trend Insight Report. Gartner. <https://www.gartner.com/en/doc/441420-how-augmented-analytics-will-transform-your-organization>, haettu 29.09.2023
- Somers, J. (2017, December). Is AI Riding a One-Trick Pony? *MIT Technology Review*, 120(6), 28–36. <https://www.technologyreview.com/2017/09/29/67852/is-ai-riding-a-one-trick-pony/>, haettu 22.10.2023.
- Storey, V. C., & Song, I.-Y. (2017). Big data technologies and Management: What conceptual modeling can do. *Data & Knowledge Engineering*, 108, 50–67. <https://doi.org/10.1016/j.datak.2017.01.001>
- Watson, H. (2014). Tutorial: Big Data Analytics: Concepts, Technologies, and Applications. *Communications of the Association for Information Systems*, 34(5), 1247–1268. <https://doi.org/10.17705/1CAIS.03462>
- Watson, H. (2019). Update Tutorial: Big Data Analytics: Concepts, Technology, and Applications. *Communications of the Association for Information Systems*, 44(3), 364–379. <https://doi.org/10.17705/1CAIS.04421>
- Wilson, H. J., & Daugherty, P. R. (2018). Collaborative intelligence: Humans and AI are joining forces. *Harvard Business Review*, 96(4), 114–123. <https://hometownhealthonline.com/wp-content/uploads/2019/02/ai2-R1804J-PDF-ENG.pdf>, haettu 05.11.2023.
- Yin, J., & Fernandez, V. (2020). A systematic review on business analytics. *Journal of Industrial Engineering and Management*, 13(2), 283–295. <http://hdl.handle.net/10419/261719>, haettu 10.11.2023.