



Vaasan yliopisto
UNIVERSITY OF VAASA

Rino Turunen

Data-analytiikan ja generatiivisen tekoälyn vaikutus kustannuslaskennan tarkkuuteen

Laskentatoimen ja rahoituksen akateeminen yksikkö
Laskentatoimen ja rahoituksen kandidaatintutkielma
Laskentatoimen ja rahoituksen kandidaattiohjelma

Vaasa 2025

VAASAN YLIOPISTO**Laskentatoimen ja rahoituksen akateeminen yksikkö**

Tekijä:	Rino Turunen		
Tutkielman nimi:	Data-analytiikan ja generatiivisen tekoälyn vaikutus kustannuslaskennan tarkkuuteen		
Tutkinto:	Kauppätieteiden kandidaatti		
Oppiaine:	Laskentatoimi ja rahoitus		
Työn ohjaaja:	Mikko Ranta		
Valmistumisvuosi:	2025	Sivumäärä:	35

TIIVISTELMÄ:

Tämän tutkielman tavoitteena on tarkastella, miten data-analytiikka ja generatiivinen tekoäly vaikuttavat kustannuslaskennan tarkkuuteen erityisesti ennustettavuuden, tehokkuuden ja luotettavuuden näkökulmasta. Teknologia alan kehitys, erityisesti generatiivinen tekoäly sekä datan määrän kasvu ovat tuoneet yrityksille mahdollisuuden analysoida kustannuksia tarkemmin sekä tehokkaammin. Koneoppimisen yleistymisen sekä syvät neuroverkot tarjoavat uusia tapoja analysoida sekä käsitellä suuria datamääriä.

Tutkielmassa havaittiin, että data-analytiikka ja business intelligence & analytics (BI&A) -työkalut parantavat kustannuslaskennan tarkkuutta automatisoinnin kautta, jolla pystytään vähentämään inhimillisten virheiden määrää. Generatiivisen tekoälyn laajat kielimallit (LLM) voivat puolestaan parantaa monimutkaisten data-analyyysien muodostamisen selkeämpään raportointiin sekä paljastaa kustannusrakenteita syvällisemmin. Tänä päivänä kuitenkin generatiivisella tekoälyllä ei voida täysin automatisoida datan analysointia, mutta sitä pystytään käyttämään tehokkaasti apuvälineenä.

Uusien teknologioiden käyttöönotto myös tuo kustannuslaskentaan uudenlaisia haasteita. Data-analytiikkaan vaikuttaa merkittävästi käsiteltävän datan laatu, jotta voidaan olla varmoja lopputulosten olevan oikeita. Generatiivisissa tekoälyissä suurimpana uhkana nähdään koulutusdatan ja algoritmien läpinäkymättömyys. Generatiivisen tekoälyn vastauksien oikeellisuudesta ei siis aina voi olla täysin varma vaan on tärkeää käyttää omaa kriittistä ajattelua.

AVAINSANAT: Data-analytiikka, Generatiivinen tekoäly, Kustannuslaskenta, Syväoppiminen, Koneoppiminen

Sisällys

Lyhenteet	4
1 Johdanto	5
1.1 Tutkielman tavoitteet ja tutkimuskysymykset	6
2 Teoreettinen viitekehys	7
2.1 Data-analytiikka liiketoiminnassa	7
2.1.1 Big data	8
2.1.2 Business intelligence & analytics	9
2.2 Generatiivisen tekoälyn kehitys	10
2.2.1 Koneoppiminen	11
2.2.2 Syväoppiminen	12
2.2.3 Generatiivinen tekoäly	13
2.3 Kustannuslaskennan nykytila	14
2.3.1 Kustannuslaskentamenetelmät	16
3 Data-analytiikan ja generatiivisen tekoälyn vaikutus kustannuslaskennan tarkkuuteen	23
3.1 Data-analytiikka ja business intelligence & analytics	23
3.2 Generatiivinen tekoäly ja syväoppiminen	25
4 Yhteenveto	27
Lähteet	29

Lyhenteet

ANN	Artificial Neural Network
BDA	Big data analytics
BI	Business Intelligence
BI&A	Business Intelligence & Analytics
CNN	Convolutional Neural Networks
ERP	Enterprise Resource Planning
FIFO	First in first out
GAN	Generative Adversarial Networks
IT	Informaatiotekniikka
KOKA	Keskimääräisomakustannusarvo
KVA	Keskimääräisvalmistusarvo
LIFO	Last in first out
LLM	Large language model
MOKA	Minimiomakustannusarvo
MVA	Minimivalmistusarvo
NOKA	Normaaliomakustannusarvo
NVA	Normaalivalmistusarvo
OKA	Omakustannusarvo
RNN	Recurrent Neural Networks
VA	Valmistusarvo
VAE	Variational Autoencoder

1 Johdanto

Kustannuslaskennan tärkeys korostuu nykyisessä kilpailullisessa liiketoimintaympäristössä. Kustannuslaskennan avulla saadaan erittäin hyödyllistä rahamääräisistä ja ei-rahamääräisistä tietoa, joka on edellytys järkevien taloudellisten päätösten teossa (Pellinen, 2019, s.43). Johdon laskentatoimen tuottamaa kustannusinformaatiota käytetään miltei kaikilla yrityksen alueilla, kuten tuotteiden hinnoittelussa, investoinneissa, asiakkaiden palvelemiseen sekä palkitsemisessa (Järvenpää ja muut, 2017, s.36). Digitalisaation myötä myös kustannuslaskentaa on viety teknologian maailmaan. Pellinen (2019) kertoo teoksessaan, että 1970-luvulta lähtien kustannuslaskentaan on ollut tarjolla valmiita ohjelmistopaketteja.

Yhä useammat yritykset ovat rakentamassa tai käyttävät toiminnanohjausjärjestelmiä (ERP) liiketoiminnassaan. ERP on ohjelmisto, joka integroi eri liiketoiminta osa-alueet yhteen ohjelmistoon. Tämä mahdollistaa suuren määrän kerättyä dataa sekä sen hyödyntämisen (Horngren ja muut, 2015, s.25). Datan yleistymisen myötä sen hyödyntäminen korostuu. Datan analysoiminen on noussut keskiöön liiketoiminnan suunnittelussa. Esimerkiksi yhdysvaltalainen kauppaketju Walmart käsittelee yli miljoonan asiakastapahtumaa päivässä, mikä tuottaa valtavan määrän dataa. Dataa ei nähdäkään enää pelkästään informaation lähteenä, vaan ”uutena öljynä” (Acito & Khatri, 2014). Datan analysointitaidot korostuvat laskentatoimen työpaikoissa nykyaikanakin entisestään. Askaryn ja Askaryn (2024, s.650) totesivat tutkimuksessaan data-analyysin olevan eniten kysytty taito Australiassa laskentatoimen alan työmarkkinoilla.

Viime vuosina generatiivinen tekoäly on noussut puheenaiheeksi sen tuomilla mahdollisuuksilla. Generatiivinen tekoäly ei ole ollut täysin uutta teknologiaa, mutta läpilyönnin aloittajana oli ChatGPT, joka julkaistiin avoimeksi sekä ilmaiseksi vuoden 2022 loppupuolella. Syvien neuroverkkojen, koneoppimisen sekä LLM:in kehittyminen antoi ChatGPT:lle valmiudet tuottaa muun muassa uutta tekstiä sekä kuvia (Feuerriegel ja muut, 2024, s.112). Silahtaroglu ja Alayoglu (2016, s.208) tutkimuksessaan korostavat nykyaikaisten

ohjelmistojen olevan mahdollisuus tehdä pitkän aikavälin liiketoimintapäätöksiä, mutta on kuitenkin haastavaa sanoa käytön oikeellisuudesta.

1.1 Tutkielman tavoitteet ja tutkimuskysymykset

Generatiivinen tekoäly on ollut viime vuosina suuri mielenkiinnon kohde tutkimuksissa, sekä sen koetaan muuttaneen tutkimuksia sekä koulutusta merkittävästi. Yusuf ja muut (2024, s.12) toteavat tutkimuksessaan, että vuonna 2022 julkaistiin vain 3 generatiivisen tekoälyn tutkimusta, kun taas vuosina 2023 ja 2024 julkaistiin yhteensä 404. Kandidaattitutkielman tutkimuskysymykset ovat seuraavat:

1. Millä tavoin data-analytiikan ja generatiivisen tekoälyn kehitys vaikuttaa kustannuslaskennan tarkkuuteen?
2. Mitkä ovat data-analytiikan ja generatiivisen tekoälyn tuomat edut ja haasteet kustannuslaskennan tarkkuudessa?

Tutkielman päätavoitteena on selvittää data-analytiikan ja generatiivisen tekoälyn vaikutukset kustannuslaskennan tarkkuuteen, sekä selvittää näiden tuomat edut ja haasteet. Tutkielmassa tarkastellaan kustannuslaskennan tarkkuutta sen ennustettavuuden, tehokkuuden sekä luotettavuuden näkökulmasta. Tavoitteena on käyttää mahdollisimman tuoreita laskentatoimen sekä muiden alojen tutkimuksia näiden kysymysten selvittämiseksi.

2 Teorettinen viitekehys

Tässä luvussa tarkastellaan data-analytiikan, generatiivisen tekoälyn sekä kustannuslaskennan teoreettiset viitekehukset, joiden ymmärtäminen on tarpeellista. Nämä luovat pohjan tutkimuksen kirjallisuuskatsauksen ymmärtämiseen.

2.1 Data-analytiikka liiketoiminnassa

Data-analytiikan hyödyntämisen vallankumousta on ollut mahdotonta olla huomamatta liiketoiminnassa. Googlen entinen toimitusjohtaja Eric Schmitt kertoi teknologia konferenssissa (2010, Lake Tahoe), että vuoteen 2003 mennessä kerätyn datan määrä kerättiin vuonna 2010 joka toinen päivä ja vauhti datan keräämisessä kiihtyy vuosi vuodelta.

Data-analytiikka voidaan jakaa kolmeen päätyyppiin: deskriptiiviseen, prediktiiviseen sekä preskriptiiviseen analytiikkaan. Deskriptiivinen data-analytiikka keskittyy historialliseen dataan sekä auttaa havaitsemaan muutoksia sekä vertailukohtia historiaan liittyen. Prediktiivinen data-analytiikka hyödyntää koneoppimista sekä tekoälyä ennustamaan sekä optimoimaan tulevaisuutta (Jeyanthi ja muut, 2022, s.4-6). Prediktiivisessä analytiikassa käytetään useimmiten suuria määriä dataa koneoppimisen optimointiin liittyen. Koneoppimisen algoritmit voivat paljastaa monimutkaisemmista taloudellisista datalähteistä analyysejä sekä ennustamista esimerkiksi yrityksen todennäköisyydestä päätyä konkurssiin (Ranta ja muut, 2023, s.620). Preskriptiivinen data-analytiikka keskittyy siihen "mitä pitäisi tehdä". Preskriptiivinen hyödyntää syvemmin koneoppimista, maattista ohjelmointia sekä simulointia. Preskriptiivinen analytiikka keskittyykin enemmän suositusten antamiseen tietoon pohjautuen (Jeyanthi ja muut, 2022, s.7-11).

Datan analysoiminen voi tukea nopeampaa päätöksien tekoa sekä parantaa niiden laatua, mutta Acito ja Khatri (2014) kuitenkin painostavat myös sen haasteita. Datan kerääminen eri lähteistä sekä erityisesti strukturoimattoman datan käsittely sekä integroiminen voi olla haastavaa. Datan keräämisessä voi myös syntyä haasteita, sillä tiedonlouhinnassa on

tarve kirjoittaa algoritmit uudelleen. Kashyap (2019) kertookin teoksessaan tiedonlouhinnan tarvitsevan asiantuntevia kehittäjiä.

2.1.1 Big data

Datan kiihtyvän määrän seurauksena suurelle määrälle dataa on tullut käsite big data. Käsitteessä on kuitenkin haasteena tarkat määritelmät big datalle, sillä sitä ei olla määritelty yksiselitteisesti. Selkeimmäksi määritelmäksi on kuitenkin kuvailtu datan valtava määrä (Pence, 2014, s.160). Näiden suurien data määrien tuominen visuaalisesti sekä analyttisesti ymmärrettäväksi voi mahdollistaa yrityksen tehokkaampaan markkinointiin, uusiin tulomahdollisuuksiin sekä paremmin kohdennettuun asiakaspalveluun (Begum & George, 2017, s.1650).

Pence (2014) kertoo artikkelissaan, että big datan ominaisuudet on tiivistetty 3 V:hen; volume (määrä), variety (moninaisuus) sekä velocity (nopeus). Määrällä tarkoitetaan big datan valtavia datamääriä, joissa on kyse sadoista teratavuista aina zetataavuihin asti. Yksi zetataavu on 1 000 000 000 teratavua. Moninaisuudella Pence (2014) tarkoittaa hämmästyttävän erilaisia strukturoituja ja strukturoimattomia datamuotoja. Nopeudella tarkoitetaan taas ei pelkästään datan nopeaa liikettä, vaan datan keräämisen, analysoinnin ja hakemisen nopeutta. Tiivistettynä, voidaan kertoa big datan olevan tietovara, jolle on ominaista niin suuri määrä, nopeus ja monimuotoisuus, että sen muuntaminen arvoksi edellyttää erityisiä teknologioita ja analyysimenetelmiä (De Mauro ja muut, 2016, s.131).

Datan moninaisuus sekä ominaisuudet nähdään usein positiivisena tekijänä, mutta ne tuovat myös omia haasteitaan. Big datan moninaisuus, kerääminen sekä käsitteleminen on haasteellinen yrityksille prosessoinnissa. Käsitteilyssä edellytetään teknologista apua, jotta big datasta saatu tieto on tehokasta sekä työskentelyä saadaan kehitettyä (Deniwara ja muut, 2020, 381). Ghasemaghaei (2018) tutkimuksessaan toteaa, että big datan tuomat hyödyt voivat olla yrityksille pienemmät kuin haasteet ja kustannukset. Tutkimuksessa myös korostetaan big datan tietoturva ja yksityisyys haasteita, jos käsitellään arkaluontoisia henkilökohtaisia tietoja (Ghasemaghaei, 2020, s.401).

2.1.2 Business intelligence & analytics

Business intelligence (BI) termistä tuli 1990-luvulla yleinen termi liiketoiminnan ja tietotekniikka yhteisöissä. Perinteisesti BI-termiä on kuvailtu sateenvarjoterminä erilaisille metodeille ja konsepteille kehittämään liiketoimintapäätöksiä. Tässä olennaisena on erilaisten tukijärjestelmien käyttö. Vuodesta 2004 lähtien kun internet sekä tietojärjestelmät ovat kehittyneet vauhdilla, on myös BI kehittynyt sen mukana (Lim ja muut, 2013, s.17-17:2). Chen ja muut (2012, s.1166) kertovat tutkimuksessaan, että BI&A sekä big data analytiikka (BDA) olevan toisiinsa liittyviä termejä. BI&A termi voidaan jakaa kolmeen vaiheeseen kehityksen myötä; 1.0, 2.0 sekä 3.0. Näiden kolmen vaiheen suurimmat eroavaisuudet ovat datan keräämisessä sekä hallinnoinnissa.

Ensimmäisellä vaiheella BI&A 1.0 viitataan pääosin strukturoitujen tietojen keräämiseen, käsittelyyn sekä analysoimiseen perinteisten tietokantajärjestelmien kautta. Tässä vaiheessa hyödynnetään muun muassa tietovarastoja (data warehousing) sekä erilaisia analyysityökaluja. Suurin osa 1.0 vaiheen datankäsittelyn sekä analyttisen teknologian BI&A alustoja tarjosi suurimmat informaatiotekniikka (IT) -yrityksen kuten Microsoft, IBM, Oracle sekä SAP. 2000-luvun alusta lähtien Web 2.0 mahdollisti uuden vaiheen, jonka myötä muodostui uusi vaihe BI&A 2.0. Web 2.0 mahdollisti strukturoimattoman datan hyödyntämisen, kuten verkkosivustojen, sosiaalisen median alustojen sekä käyttäjien tuottaman datan analysoinnin. BI&A 3.0 vaiheessa kehittyvät mobiililaitteet, kuten älypuhelimet sekä tabletit mahdollistivat eri sovellusten ja sijainnin keräämän datan analysoinnin (Chen ja muut, 2012, s.1166-1168).

BI&A ohjelmistojen käyttöönotossa kuitenkin nähdään haasteita. Xuefei ja Lei (2012) huomasivat tutkimuksessaan, että BI&A liittyvissä raportoinneissa sekä datassa on nähty ongelmia. Tutkimuksessa myös korostettiin myös käytönoton alkuvaiheessa huomattiin eniten ongelmia. Tämän takia järjestelmien tunteminen alkuvaiheessakin on olennaista. Myös myöhemmin käyttöönotosta on tärkeää, että järjestelmää käytetään tehokkaasti

ja se liittyy olennaisesti päätöksentekoprosesseihin (Rikhardsson & Yigitbasioglu, 2018, s.47).

2.2 Generatiivisen tekoälyn kehitys

Tekoäly on vahvasti noussut huomioon vuonna 2022 ChatGPT:n julkaisun aikoina. Tekoälyn viimeisin vallankumous ei kuitenkaan alkanut siitä, vaan tämän eteen oli tehty valtavat määrät pohjatyötä. ChatGPT:n julkaisu ajatellaan olevankin tekoälyn kehityksen käännekohta (Ojanperä, 2023, s.8). Tekoälyn kehityksestä puhuttaessa usein käytetään termejä ”kevät” ja ”talvi”. Keväällä tarkoitetaan tekoälyn kehityksen alalla onnistumisen kokemuksia ja talvella taas viitataan pettymyksiin (Ojanperä, 2023, s.24).

Vuonna 1950 tekoälyn keksijänä tunnettu englantilainen matemaatikko Alan Turing julkaisi artikkelin ”Computing Machinery and Intelligence”, missä hän kertoi tavan testata koneiden älykkyyttä. Turingin testin ajatellaan vielä tänä päivänäkin olevan lähtölaukaus tekoälylle. Tekoäly sanana kuitenkin keksittiin vuonna 1956 Marvin Minskyn ja John McCarthyn toimesta. He pitivät noin kahdeksan viikon pituisen ”Darthmouth Summer Research Project on Artificial Intelligence” seminaarin. Tästä seminaarista alkoi tekoälyn ensimmäinen kevät (Haenlein & Kaplan, 2019, s.7).

Tekoälyn ensimmäisen kevään hedelmiä alkoi tuottamaan saksalainen Joseph Weizenbaum vuonna 1966, kun julkaistiin ensimmäinen julkisesti tunnettu chatbot Eliza. Eliza pystyy keskustelemaan ihmisen kanssa perustuen käsin kirjoitettuun tekstiin. Tämä chatbot ei kuitenkaan ymmärrä keskustelua vaan yrittää etsiä mallisovituksen avulla jonkun järkevä vastauksen. Weizenbaum yritti kehittämällään Elizalla ensimmäistä kertaa yrittää läpäistä Turingin testiä, mutta ei onnistunut siinä (Shum ja muut, 2018, s.11-12).

Haenlein ja Kaplan (2019) kertoo artikkelissaan, että Elizan jälkeen onnistumistarinan teki Nobel-palkittu Simon Herbert sekä kanssatutkijat Cliff Shaw ja Allen Newell. Herbert ja muut kehittivät ohjelman, joka pystyi ratkaisemaan automaattisesti tietynlaisia ongelmia kuten Hanoin tornit. Tämän ohjelman jälkeen vuonna 1973 kuitenkin Yhdysvaltain

kongressi kritisoi tekoälyn kehityksen korkeita menoja ja tämän jälkeen Iso-Britannian lopetti tekoälyn kehityksen tuen. Nämä tapahtumat aloittivat tekoälyn kehityksen talven (Haenlein & Kaplan, 2019, s.7).

Keinotekoiset neuroverkot (ANN) nousivat puheenaiheeksi 1980-luvulla tekoälyn kehityksessä. Neuroverkot yrittävät jäljitellä ihmisten aivojen neuroverkkoja informaation prosessoinnissa sekä muistissa (Jenkins & Tangauay, 1995). Ensimmäisten neuroverkko-ohjelmistojen myötä alettiin taas elämään tekoälyn kehityksen kevättä (Ojanperä, 2023, s.26).

2.2.1 Koneoppiminen

Koneoppimisen kehitys alkoi, kun huomattiin ohjelmointisääntöisten koneiden olevan puutteellisia monimutkaisten ongelmien ratkaisussa. Koneoppiminen on tekoälyn osa-alue, jossa tekoäly kehittyy ja oppii datan perusteella. Tekoälyn koneoppimisprosessia voi verrata lapseen, joka tarvitsee paljon toistoja oppiakseen. Tekoällylle täytyy siis syöttää lisää dataa, jotta se oppii antamaan tarkempia vastauksia. Koneoppimisen menetelmät voidaan jakaa kolmeen eri päätyyppiin: ohjattuun oppimiseen (supervised learning), ohjaamattomaan oppimiseen (unsupervised learning) sekä vahvistusoppimiseen (reinforcement learning) (Ojanperä, 2023, s.25).

Ohjatussa oppimisessa malli koulutetaan harjoitusaineistojen avulla luomaan yhteys syötteen (input) sekä tiedetyn tulosteen (output) välille. Ohjattuun oppimiseen koulutettu malli soveltuu parhaiten luokittelu- ja regressiotehtäviin. Kouluttamisen avulla malli pystyy tuottamaan odotetun tulosteen, kun uusi syöte on annettu. Ohjaamaton oppiminen etsii taas itse piilossa olevia kuvioita ja rakenteita merkitsemättömästä datasta. Tämä malli oppii siis käyttämään aiempia opittuja piirteitä uusien syötteiden tunnistamisessa (Yazici ja muut, 2023, s.7-8). Vahvistusoppimisessa malli taas oppii kokeilemalla sekä virheistään. Malli saa joko positiivista tai negatiivista palautetta jokaisesta tulosteestaan. Ojanperä (2023) käyttää kirjassaan seuraavaa havainnollistavaa esimerkkiä:

itseohjautuvalle autolle positiivinen palaute voi olla, että auto pysähtyy punaisiin valoihin eikä tönäise suoja tiellä kulkevaa henkilöä, kun taas negatiivinen palaute olisi, jos auto tönäisee henkilöä. Näin malli pystyy itse kehittämään omia tulosteitaan.

Koneoppimisen menetelmiä on useita, mutta laskentatoimen alalla menetelmät ovat vielä alkuvaiheessa. Koneoppimisen menetelmät ovat vahvimmillaan ongelmassa, missä on useampi muuttuja ja niiden vuorovaikutuksia keskenään ei voida teoreettisesti todeta. Koneoppiminen on myös erityisen hyödyllinen strukturoimattoman datan käsittelyssä, sillä data voi olla monimutkaista sekä haastavaa käsitellä sekä ymmärtää. Laskentatoimen alalla on hyödynnetty tämän myötä valvomattomia koneoppimisen menetelmiä ymmärtääkseen monimutkaista dataa sekä tekemään uusia teorioita ja mittareita (Bertomeu ja muut, 2021, s.488; Ranta ja muut, 2023, s.615-616).

2.2.2 Syväoppiminen

Datan määrän suuren kasvun, saavutettavuuden sekä teknologian kehittymisen myötä ruvettiin tutkimaan syväoppimisen (deep learning) mahdollisuutta. Syväoppiminen on koneoppimisen osa-alue, joka hyödyntää syviä neuroverkkoja mallintaakseen suuria datamääriä (Pouyanfar ja muut, 2019, s.92-92:2). Neuroverkot sisältävät suuria määriä neuroneita, toisin sanoen yksinkertaisia yksiköitä. Nämä neuronit voidaan muodostaa Ojanperän (2023) mukaan kolmeen osaan: syöttökerrokseen, yhteen tai useampaan piilotettuun kerrokseen sekä ulostulokerrokseen. Syvässä neuroverkossa näitä kerroksia on useita.

Syvän neuroverkon kerroksien rakenteesta käytetään nimitystä arkkitehtuuri. Arkkitehtuurit vaikuttavat suoraan mallin kykyyn oppia sekä mallintaa monimutkaisia datarakenteita. Arkkitehtuureja on useita ja ne ovat suunniteltu erilaisiin tehtäviin ja datarakenteisiin. Yleisimpiä arkkitehtuureja ovat konvoluutiohermoverkko (convolutional neural networks, CNN), toistuvat hermoverkot (recurrent neural networks, RNN), transformer-verkot sekä generatiiviset vastakkaisverkot (generative adversarial networks, GAN) (Pouyanfar ja muut, 2019, s.92:2-92:4).

2.2.3 Generatiivinen tekoäly

Generatiiviselle tekoälylle on koulutettu valtavia tietomääriä tuottaakseen käyttäjän antamiin syötteisiin (prompteihin) perustuvia tulosteita (Sætra, 2023; Ojanperä 2023). Terminä generatiivinen tekoäly tarkoittaa Feuerriegelin ja muiden (2023) mukaan laskennallisia tekniikoita, jotka ovat kykeneviä tuottamaan uutta ja merkityksellistä sisältöä, kuten tekstiä, kuvia tai ääntä koulutetusta datasta. Generatiivinen tekoäly eroaakin perinteisestä tekoälystä siten, että se ei pelkästään analysoi tai luokittele dataa, vaan luo jotain uutta. Goldman Sachsh (2023) on tutkinut, että generatiivinen tekoäly tulee nostamaan maailman laajuisesti talouden tehokkuutta sekä maailman bruttokansantuotetta (BKT) noin 7 %.

Generatiivisen tekoälyn malli perustuu jo aiemmin mainittuun syvään neuroverkkoon. Syvät neuroverkot soveltuvat erittäin hyvin generatiivisen tekoälyn malliin, sillä syviä neuroverkkoja voidaan soveltaa erilaisilla arkkitehtuureilla käsittelemään erilaista dataa kuten sekventiaalista dataa (esim. ihmiskieltä) tai spatiaalista dataa (esim. kuvat) (Feuerriegel ja muut, 2024, s.112). Generatiivisen tekoälyn malleja on useita ja täytyykin ymmärtää mitä mallia käyttää mihinkin käyttötarkoitukseen.

Viime vuosina laajaa huomiota yhteiskunnassa herättänyt tekoäly malli on ollut LLM, kun ChatGPT julkaistiin. LLM on koulutettu miljardeilla parametreilla ja tämän avulla se pystyy ymmärtämään ihmisen arkikieltä sekä pystyy vastaamaan ihmisen lailla. LLM on parhaimmillaan tekstin luomisessa ja promptien ymmärtämisessä (Bandi ja muut, 2023, s.18; Feuerriegel ja muut, 2023, s.112). LLM hyödyntää erityisesti erästä tekoälyn arkkitehtuuria, transformeria. Tämän arkkitehtuurin etuna muihin arkkitehtuureihin on rakennettu neuroverkkoarkkitehtuuri, jota koulutetaan jatkuvasti uusilla parametreilla. Parametrien voidaan ajatella olevan tekoälyn aivot, mitä enemmän sille koulutetaan parametreja, tulee siitä älykkäämpi (Kalyan ja muut, 2021; Ojanperä 2023).

Generatiivinen tekoäly ei kuitenkaan rajoitu pelkästään transformer-arkkitehtuurin ja LLM:in ympärille. Nämä ovat kuitenkin mullistaneet generatiivisen tekoälyn ihmismäisen käytön (Ojanperä, 2023). Generatiivisen tekoälyn perusarkkitehtuureja ovat myös variatiivinen autoenkooderi (variational autoencoder, VAE) sekä GAN. VAE soveltuu erityisesti kuvien rekonstruointiin, sillä se käyttää todennäköisyyspohjaista enkoodaus-dekoodausmenetelmää. GAN sen sijaan perustuu vastakkain asetettuun koulutustilaan, sillä se koostuu niin sanotusti kahdesta pelaajasta; generaattorista (generator) ja diskriminaattorista (discriminator). Generaattorin tehtävä on yrittää huijata diskriminaattoria, kun taas diskriminaattorin tehtävä on yrittää tunnistaa generaattorin näytteen oikeellisuus todellisesta jakaumasta. Näiden kahden pelaajan avulla GAN pyrkii tuottamaan kriittisen ajattelun tavalla tulosteita. GAN soveltuukin parhaiten kuvien luomiseen, tiivistämiseen sekä datan parantamiseen (Sharma ja muut, 2022; Bandi ja muut, 2023).

Generatiivisen tekoälyn käyttö laskentatoimen alalla on vielä alkuvaiheessa, mutta hyödyntämiskohteita on kuitenkin löydetty. ChatGPT pystyy LLM:in avulla käsittelemään dataa sekä tekstejä nopeasti sekä tarkasti. Generatiivisella tekoälyllä pystytään automatisoimaan taloudellisten raporttien laadinta, joka tuottaa tehokkaasti sekä tarkasti taloudellisia- että analyysiraportteja. Myös ennustavan koneoppimisen avulla pystytään analysoimaan sekä ennustamaan tietoja, jotka voivat vaikuttaa investointien sekä taloustuotteiden riskienottamiseen (Cao ja muut, 2024, s.6).

2.3 Kustannuslaskennan nykytila

Kustannuslaskenta on yksi tärkein osa-alue johdon laskentatoimea, sillä se on edellytys päätöksenteolle sekä toiminnanohjaukselle. Kustannuslaskennan päätehtävä on selvittää tuotteen tai palvelun aiheuttamat kustannukset (Kohli, 2009, s.3-4). Terminä kustannuslaskenta tarkoittaa prosessia ja tekniikoita, joilla taloudellisia ja ei-taloudellisia tietoja mitataan, analysoidaan ja raportoidaan. Kustannuslaskennan laatiminen on erityisen olennaista tilinpäätösraportointia varten, jotta saadaan selville valmisteveraston arvo

selville. Kustannuslaskenta myös tuottaa olennaista tietoa, jotta yritys pystyy hyödyntämään tietoa tekemään taloudellisesti järkeviä päätöksiä (Horngren ja muut, 2015, s.26; Pellinen, 2019, s.43).

Kustannuslaskenta on järjestelmien avulla kehittynyt tarkempaan suuntaan esimerkiksi tavoite on keskittynyt enemmän kustannustietojen tarkkuuteen ja relevanssiin erityisesti kilpailukyvyyn parantamiseksi. Laitinen (2014) kertoo tutkimuksessa kustannuslaskennan muutoksilla olevan pieni vaikutus taloudelliseen suorituskykyyn. Kustannuslaskennan kehittymisellä on vaikutusta kustannusten vähentämiseen ja resurssien optimointiin. Haasteena kuitenkin kustannuslaskennan muutoksissa on niiden aiheuttamat lisäkustannukset sekä epävarmuudet (Laitinen, 2014).

Kustannuslaskentaa ymmärtääkseen on tärkeää käydä läpi kustannuksen ero menoon ja kuluun. Menolla tarkoitetaan hankintahetkellä hyödykkeen tai palvelun rahamaksua. Esimerkiksi jonkin koneen ostotapahtuma luokitellaan menoksi. Kulu on taas tilikaudelle kohdistettu maksun osa. Kulu ei välttämättä ole rahavirtainen tapahtuma, vaan voi olla esimerkiksi omaisuuden poistoja tai kulumista. Kustannus on taas niin sanottu taloudellinen uhraus, jonka avulla pyritään taloudelliseen tuottoon tai hyötyyn (Ikäheimo ja muut, 2019, s.131). Pellinen (2019) toteaa teoksessaan kustannusten olevan joko rahamaksuja tai rahattomia uhrauksia. Maksuperusteisia rahamaksuja kutsutaan myös pagatorisiksi kustannuksiksi ja tämänlainen kustannus voi olla esimerkiksi varaston katon korjaaminen. Rahattomat uhraukset voivat olla esimerkiksi työaikaa, osaamista tai liikesuhteita ja näitä kutsutaan kalkulatorisiksi kustannuksiksi.

Kustannukset voidaan myös jaotella tyyppien mukaan kahteen perustyyppiin; muuttuviin- ja kiinteisiin kustannuksiin. Muuttuvien kustannusten määrä muuttuu suhteessa sen lopputuotteen tai kokonaisaktiivisuuden määrän muutoksiin. Kiinteät kustannukset pysyvät saman määräisinä riippumatta lopputuotteen määrän muutoksista (Horngren ja muut, 2015, s.54). Horngren ja muut (2015) käyttävät teoksessaan näiden eri kustannus-

tyyppien havainnollistamiseen esimerkkinä BMW X6 henkilöauton kustannuksia. He kertovat muuttuvasta kustannuksesta esimerkkinä rattia sekä kiinteistä kustannuksista esimerkkinä työnvalvojaa. Rattien valmistamisen kokonaiskustannus nousee, kun tuotetaan uusi henkilöauto. Työnvalvojalle maksetaan kiinteä palkkio työstä, riippumatta henkilöautojen valmistusmäärästä. Ikäheimo ja muut (2019) kertovat teoksessaan olevan kolmaskin kustannusten päätyyppi; puolikiinteät kustannukset. Tämänlaiset kustannukset voivat olla kiinteitä kustannuksia, mutta voivat nousta kerralla uuteen kiinteään kustannukseen. Puolikiinteä kustannus voi olla esimerkiksi työntekijöiden palkat, jos yrityksellä on tarve lisätyövoimalle.

2.3.1 Kustannuslaskentamenetelmät

Ikäheimon ja muiden (2019, s.130) mukaan kustannuslaskennalla on kolme päätehtävää; varaston arvostus, vastuualuelaskenta sekä tuote-, palvelu- ja asiakaskohtaisten kustannusten määrittäminen. Varastot ovat tärkeitä sekä varsin yleisiä varsinkin teollisuus- ja kaupan alan yrityksille, sillä varaston avulla voidaan tasata kysynnän vaihteluita sekä mahdollistaa tuotteen nopean toimituksen (Pellinen, 2019). Varaston arvostuksen laskeamiseen otetaan huomioon eri kustannuksia ja lainsäädäntö ohjaa, mitä kustannuksia arvoon voidaan sisällyttää. Vastuualuelaskennalla tarkoitetaan kustannuksien kirjaamista kustannuspaikoille ja alueille, mitkä ovat aiheuttaneet kustannukset. Horngren ja muut (2015) korostavat teoksessaan organisaatio rakenteen sisältävän vastuualuekeskuksia, joista vastaavat toiminta-alueen johtajat. Vastuualuelaskentaa kutsutaankin usein myös kustannuspaikkalaskennaksi. Kolmas päätehtävä, tuote-, palvelu- ja asiakaskohtaisten kustannusten määrittäminen tarkoittaa vastuualueiden kustannusten tarkempaa selvittämistä. Tämä päätehtävä tarjoaa arvioinnin vastuualueiden kannattavuudesta ja on erityisen tärkeää myös pohtia tuottojen kohdentamista mahdollisimman tehokkaalla tavalla (Ikäheimo ja muut, 2019). Kustannuslaskentajärjestelmät ovat kykeneviä analysoimaan eri tasoilla kustannuksia. Näitä ovat muun muassa kustannuspaikat, tuotekohtaiset kustannukset sekä aktiviteetit. Järjestelmät myös pystyvät tarjoamaan tarkkaa tietoa kustannuspaikoista, joiden avulla pystytään tarjoamaan parempaa tukea päätöksentekoon sekä resurssien hallintaan (Cohen & Kaimenaki, 2011, s.14-17).

Kustannuslajilaskenta

Kustannukset jaetaan kustannuslajeiksi, joka on kustannuslajilaskennan perusta. Kustannuslajilaskenta on kustannuslaskennan ensimmäinen vaihe, jossa kustannukset lajitellaan tyyppin mukaan eri tileille ja kokoaa niin sanotun tilikartan. Suurilla yrityksillä tilikartta voi koostua tuhansista tileistä (Ikäheimo ja muut, 2019). Kustannukset jaotellaan Järvenpään ja muiden mukaan (2017) neljään tuotannontekijään; työsuorituksiin, aineisiin, lyhytvaikutteisiin tuotannonvälineisiin sekä pitkävaikutteisiin tuotannonvälineisiin. Työsuoritukset pitävät sisällään palkkakustannukset sekä lakisääteiset- että vapaaehtoiset henkilösivukustannukset. Aineista aiheutuvat ainekustannukset selvitetään yleensä inventaarion avulla. Lyhytvaikutteisilla tuotantovälineillä tarkoitetaan tarvike-, vuokra-, energia-, sekä kuljetuksen ja muiden kustannuksia. Muut lyhytvaikutteiset kustannukset yleensä käytetään nopeasti hankittaessa. Viimeinen ryhmä, pitkävaikutteiset tuotantovälineet sisältävät poisto-, korko- sekä vakuutuskustannukset. Näitä myös kutsutaan pääomakustannuksiksi, sillä nämä liittyvät olennaisesti pääoman hallintaan (Järvenpää ja muut, 2017, s.73-82).

Kustannuslajilaskennan avulla saadaan tietoon voimavarojen yksikkökustannukset, mutta tämän menetelmän yksi vahvoista puolista on myös saada tietoon varaston arvostus. Varastoa arvostetaankin alkuperäisen hankintahinnan mukaan ja sitä voidaan soveltaa eri menetelmillä. Näitä menetelmiä ovat FIFO- (first in first out) ja LIFO- (last in first out) menetelmät sekä punnitun keskihinnan ja juoksevan keskihinnan menetelmät. FIFO ja LIFO-menetelmässä otetaan huomioon aineiden sisään tulojärjestys. FIFO:ssa ainekset käytetään varastoon tulo järjestyksessä, kun taas LIFO:ssa varastoon viimeksi tulleet aineet käytetään ensimmäisenä. Punnitun keskihinnan menetelmässä oletetaan aineiden tai materiaalien olevan samanlaatuisia tai että varastointi tapahtuu samalla tavalla (Järvenpää ja muut, 2017, s.78). Pellinen ja muut (2019) kertovat teoksessaan punnitun keskihinnan laskentatavaksi alkuvaraston arvon sekä laskentakauden aikana saapuneiden materiaalien arvon summan jaettavaksi kappalemäärällä. Juoksevassa keskihinnassa

sovelletaan punnittua keskihintaa siten, että se lasketaan jokaisen saapumiserän yhteydessä uudestaan (Järvenpää ja muut, 2017, s.78).

Kustannuspaikkalaskenta

Yritykset koostuvat vastuualueista sekä toimintayksiköistä, joita kutsutaan kustannuslaskennassa kustannuspaikoiksi. Tämän takia kustannuspaikkalaskentaa kutsutaankin myös vastuualuelaskennaksi. Kun aikaisemmassa kustannuslajilaskennassa lasketaan lajien perusteella, kustannuspaikkalaskennassa selvitetään tarkemmin mikä toimintayksikkö tai vastuualue ovat kustannukset tuottaneet. Käytännön esimerkkejä kustannuspaikasta voisi olla aine- hallinnon sekä markkinoinnin kustannuspaikat. Kun välittömät kustannukset voidaan kohdistaa suoraan suoritteelle, välilliset kustannukset taas viedään ensin kustannuspaikoille. Kustannuspaikkalaskennan toinen tärkeä tehtävä eri vastuualueiden tuotettujen kustannusten selvittämisen rinnalla on myös perustan luominen yleiskustannuslajien selvittämiseksi (Ikäheimo ja muut, 2019, s.140, Järvenpää ja muut, 2017, s.90). Kustannuspaikoittain raportointi myös mahdollistaa selkeämpää kuvaa organisaation kustannusrakenteista, mikä voi helpottaa niiden hallintaa sekä optimointia (Cohen & Kaimenaki, 2011, s.14-15).

Kustannuspaikat jaetaan kahteen pääryhmään; apu- ja pääkustannuspaikkoihin. Pellisen (2019) teoksen mukaan apukustannukset tarkoittavat esimerkiksi niitä aineiden tuotantoyksiköitä tai tehdaspalveluita, jotka ovat osana usean eri lopputuotteen valmistuksessa. Pääkustannuspaikan aiheuttamat kustannukset ovat taas välittömästi lopputuotteeseen kohdistuvia. Apukustannuspaikkojen kustannukset liittyvät pääkustannuspaikkoihin siten, että apukustannuspaikkojen kustannukset kohdistetaan pääkustannuspaikoille eri metodeilla. Tämän avulla suoritekustannuksiin sisällytetään apukustannuspaikkojen kustannukset (Järvenpää ja muut, 2017, s.90-91). Kustannusten kohdistamismetodeiksi luokitellaan suoraan, vaiheittain ja ristikkäin. Suorassa kohdistamisessa pystytään suoraan kertomaan sille kuuluva pääkustannuspaikka. Vaiheittain ja ristikkäin kohdistamisessa tiedetään jonkin vastuualueen palvelevan useaa muutakin vastuualuetta, kuten esimer-

kiksi valaistuksen energiakustannukset. Vaiheittaisessa kohdistamisessa otetaan huomioon jonkun vastuualueen palvelevan enemmän toista vastuualuetta kuin toista. Tätä kohdistamistapaa kutsutaankin myös termillä vyöryttäminen, koska kustannukset vyörytetään yksi kerrallaan vähemmän vastuisille. Ristikkäisessä kohdistamisessa otetaan huomioon vastuualueiden vastavuoroiset kustannukset ja nämä jaetaan siten, että kustannukset kohdistetaan palvelujen käytön suhteessa (Järvenpää ja muut, 2017, s.72-73).

Suoritekohtainen kustannuslaskenta

Kustannuslaskennan viimeinen vaihe on suoritekohtainen kustannuslaskenta, joka tarjoaa yritykselle tarkempaa tietoa yksittäisen tuotteen, palvelun tai projektin valmistamisesta aiheutuvista kustannuksista. Suoritteella tarkoitetaan Ikäheimon ja muiden (2019) mukaan tuotetta tai palvelua. Suoritekohtainen kustannuslaskenta tarjoaa tärkeää tietoa muun muassa hinnoitteluun, tuotevalikoimaan sekä tuotannon kehittämiseen liittyen. Myytyjen tuotteiden sekä varastossa olevien tuotteiden kustannusten erottelu on myös olennaista tilinpäätösraportoinnin kannalta (Pellinen, 2019, s.74).

Suoritekohtaista kustannuslaskentaa suunnitellessa on olennaista tietää tarkemmin mitä kustannuksia lasketaan. Erilaisia laskelmia liittyen suoritekohtaisten kustannusten laskentaan kutsutaan termillä kalkyyli. Kalkyyliit jaetaan kolmeen luokkaan; minimi-, keskimääräis- sekä normaalikalkyyleihin. Kalkyyleiden avulla saadaan tietoon suoritteiden yksikkökustannukset. Näiden kalkyylien suurin ero on muuttuvien- ja kiinteiden kustannusten huomioon ottaminen. Minimikalkyyliin otetaan pelkästään huomioon muuttuvat kustannukset, joten minimikalkyyli on paras vaihtoehto muuttuvien kustannusten osuuden ollessa suuri kokonaiskustannuksista. Minimikalkyylin yksikkökustannukset lasketaan siten, että muuttuvat kokonaiskustannukset jaetaan toteutuneella suoritemäärällä (Järvenpää ja muut, 2017, s.114). Keskimääräiskalkyyllissä otetaan huomioon kaikki laskentakauden kustannukset. Keskimääräiskalkyylin käyttö on yleisintä teollisuudessa sekä palvelutoiminnassa kiinteiden kustannusten osuuden ollessa suuri. Keskimääräiskalkyylin yksikkökustannukset saadaan tietoon, kun muuttuvat- ja kiinteät kustannukset jae-

taan laskentakauden toteutuneella suoritemäärällä. Normaalikalkyyli eroaa keskimääräiskalkyylistä siten, että siihen otetaan huomioon normaalituotanto. Normaalituotannolla tarkoitetaan sitä tuotannotilannetta, johon tiedetään kokemuksen avulla pääsevän yli tuotannon vaihtelusyklin (Ikäheimo ja muut, 2019, s.138-139; Pellinen, 2019, s.74-45).

Näiden eri kalkyylien yksikkökustannusten avulla voidaan selvittää suoritteen arvo. Kalkyylien laskennasta saadut suoritteen arvot jaetaan kalkyylien ja kustannustyyppien mukaan valmistusarvoksi (VA) sekä omakustannusarvoksi (OKA) (Pellinen, 2019, s.76). VA:oon lasketaan ne kustannukset mukaan, jotka ovat aiheutuneet suoritteen tai tuotteen valmistamisesta. Tämänlaisia kustannuksia esimerkiksi voivat olla tuotantokustannukset. OKA:ssa otetaan huomioon laajemmin kustannukset, sillä se sisältää valmistuksessa aiheutuvien kustannusten lisäksi hallinnon sekä markkinoinnin kustannukset (Järvenpää ja muut, 2017, s.119). Kun VA:oon otetaan huomioon kalkyyli nämä jaetaan minimivalmistusarvoon (MVA), keskimääräisvalmistusarvoon (KVA) sekä normaalivalmistusarvoon (NVA). MVA:ssa otetaan huomioon minimikalkyyli, KVA:ssa otetaan keskimääräiskalkyyli huomioon sekä NVA:ssa taas normaalikalkyyli. OKA voidaan laskea samalla ja näitä eri kalkyylien huomioon ottavia OKA:ja kutsutaankin minimi- (MOKA), keskimääräis- (KOKA) ja normaaliomakustannusarvoiksi (NOKA) (Pellinen, 2019).

Useat organisaatiot käyttävät Ikäheimon ja muiden (2019) mukaan portaittaista katelaskelmaa, missä selvitetään VA sekä OKA. Tämän portaittaisen katelaskelma voidaan laskea soveltaen eri tarpeisiin. Käytännössä tämä katelaskelma suoritetaan aina riveittäin summaten eri arvoissa huomioon otetut kustannukset. Esimerkiksi portaittaisessa katelaskelmassa eri välivaiheita eli katteita voi olla ensimmäiseksi MVA:ssa huomioon otetut kustannukset, tämän jälkeen VA missä otetaan huomioon laajempi VA, sitten MOKA ja viimeiseksi laajempi OKA (Järvenpää ja muut, 2017, s.119-120).

Suoritekohtaisen kustannuslaskennan viimeinen vaihe riippuu suoritteiden tyypistä. Yleisimmiksi toimintamuodoiksi on todettu jako- ja lisäyslaskenta sekä toimintolaskenta. Jakolaskenta on laskentamenettelyistä yksinkertaisin, sillä siinä jaetaan tuotannon kaikki kustannukset tuotettujen suoritteiden määrällä. Tällä tavalla saadaan tulokseksi suoritteiden yksikkökustannus. Tämä soveltuu parhaiten organisaatioille, joilla suoritteet tai tuotteet ovat samankaltaisia tai tuotantoprosessi on sama. Yleisintä jakolaskenta on prosessiteollisuudella sekä energiayhtiöillä (Ikäheimo ja muut, 2019, s.139-140). Lisäyslaskennasta on useita eri tapoja laskea, sillä kustannustyyppisiä on myös useita. Lisäyslaskennassa otetaan erityisesti huomioon kustannuspaikat, jotka pystytään määrittelemään tarkemmin kustannuspaikkalaskennassa. Käytännössä kuitenkin välittömät kustannukset pyritään kohdentamaan suoritteelle ensiksi. Tämän jälkeen pääkustannuspaikkojen kustannukset kohdennetaan suoritteille niin sanottujen yleiskustannuslisien kautta. Yleiskustannuslisät pystytään määrittämään jakamalla kustannuspaikan välilliset kustannukset kustannuspaikan yksikön mukaan määrällä. Esimerkiksi palkkalisä voidaan laskea jakamalla kustannuspaikan välilliset kustannukset jakamalla välittömillä palkoilla sekä kertomalla 100 %. Tämän avulla saadaan prosenttiluku, joka kuvaa yleiskustannuslisää palkkojen osalta (Ikäheimo ja muut, 2019, s.140; Pellinen, 2019, s.87). Lukan ja Granlundin (1996, s.9) tutkimuksessa mainitaan, että Suomen yrityksissä suurin haaste kustannuslaskennassa on yleiskustannuslisien laskeminen ja kohdistaminen. Tutkimuksessa myös kerrotaan Suomen tuotantoyksiköissä olevan monipuolisempi standardi kohdistamisperusteissa kuin esimerkiksi Yhdysvalloissa. Tämä viittaa taas siihen, että Suomessa haasteet ovat monimuotoisempia (Lukka & Granlund, 1996, s.9-10).

Toimintolaskenta on Järvenpään ja muiden (2017) mukaan kirjallisuuden sekä käytännön kokemuksen perusteella parhaiten aiheuttamisperiaatetta noudattava menetelmä. Toimintolaskenta vaatii enemmän kustannuksista tietoa kuin lisäyslaskenta, mutta on myös tarkempi. Toimintolaskenta käyttää yleiskustannuksille kustannusajureita, jotka on määritettävä yksikkökustannuksina. Hankintojen kustannusajureiden hinnat pystytään määrittämään, kun kustannukset jaetaan laskujen kokonaiskappalemäärällä. Toimintolasken-

nassa pystytään ottamaan huomioon myös aika-arvo. Tämän avulla pystytään selvittämään esimerkiksi yhden tarjouspyynnön keskimääräinen hinta, kun jaetaan kokonaiskustannukset asiakaspalveluun jaettuna asiakaspalvelun työajalla (Pellinen, 2019, s.129-131; Järvenpää ja muut, 2017, s.152-154). Toimintolaskenta voi parantaa organisaation kustannustietojen relevanssia sekä tarkkuutta, sillä toimintolaskenta parantaa tiedon analysointia sekä käyttökelpoisuutta päätöksenteossa. Toimintolaskenta on kuitenkin haastavampi ottaa organisaatiossa käyttöön verrattaessa muihin. Tämä menetelmä vaatii enemmän resursseja sekä se on huomattavasti monimutkaisempi muihin menetelmiin verrattuna (Cohen & Kaimenaki, 2011).

3 Data-analytiikan ja generatiivisen tekoälyn vaikutus kustannuslaskennan tarkkuuteen

Tässä tutkielman luvussa käydään läpi tarkemmin data-analytiikan sekä generatiivisen tekoälyn vaikutusta kustannuslaskennan tarkkuuteen kirjallisuuden avulla. Erityisesti tässä luvussa tarkastellaan data-analytiikan kehittyneiden työkalujen sekä uusien generatiivisen tekoälymallien hyödyntämistä kustannuslaskennan ennustettavuuden, tehokkuuden sekä luotettavuuden parantamisessa. Tämän aiheen tarkastelussa otetaan myös huomioon niiden tuomat haasteet. Tarkastelussa pyritään käyttämään laskentatoimen tuoreita tutkimuksia.

3.1 Data-analytiikka ja business intelligence & analytics

Datan kasvun ja arvostuksen myötä uskotaan, että datan sekä big datan hyödyntäminen teknologioissa tulee nopeasti kehittämään johdon laskentatoimen tasoa (Zhang ja muut, 2020). Data-analytiikassa on useita eri metodeja sekä tapoja visualisoida dataa tukemaan taloudellisia toimia. Hesford ja muut (2024) kertovat tutkimuksessaan regressioanalyysin olevan yksi tarkimmista menetelmistä kustannusten arvioinnissa. Tämä johtuu siitä, että regressioanalyysi on objektiivinen tapa arvioida kustannusfunktion historiallista dataa eri muuttujilla. Tarkimpiin regressioanalyysiin kuitenkin vaaditaan Python tai R ohjelmistokielen hallintaa, joka voi tuoda omat haasteensa. Data-analytiikan käyttäminen kustannuslaskennassa tukee poikkeamien tunnistamisen sekä autokorrelaatiota jotka voivat vaikuttaa mallien tarkkuuteen (Hesford ja muut, 2024).

Koneoppimista käytetään data-analytiikassa erityisesti prediktiivisissä analyysissä. Koneoppimisen käyttö kustannuslaskennassa on osoittanut tarkkuuden parantamisen merkkejä. Knox (2023) toteaa tutkimuksessaan koneoppimistekniikoiden adaptoimisen toimintolaskentaan kehittävän laskennantarkkuutta, sillä neuroverkot pystyvät käsittelemään ei-lineaarisia suhteita tehokkaasti. Nämä kyvyt ovat koneoppimiselta erityisen hyödyllisiä monimutkaisissa kustannusten arviointitilanteissa. Bertomeu ja muut (2020)

korostavat myös teoksessaan koneoppimisen olevan hyödyllinen tunnistamaan syy-seuraussuhteita kustannusten aiheuttajien välillä. Koneoppimisen prediktiiviset analyysit on myös huomattu olevan tehokkaita, kun halutaan selvittää kustannusrakenteita tai suoritekohtaista kustannusta (Bertomeu ja muut, 2021). Data-analytiikan ja koneoppimisen hyödyntäminen kustannuslaskennassa voi kuitenkin tuoda suuria haasteita, jos datan laatu on puutteellinen tai virheellinen. Tämä voi viedä kustannuslaskennan datan analysoimisen väärin johtopäätöksiin (Grytz & Krohn-Grimberghe, 2018).

BI&A työkalut sekä menetelmät tarjoavat yrityksille tavan käsitellä historiallista dataa sekä tehdä johtopäätöksiä näistä. Nämä työkalut voivat tuoda kustannusten tietoja paremmin esille, sekä tehdä ennusteita käyttämällä historiallista dataa. BI&A työkaluja hyödyntämällä voi myös parantaa kustannuksien läpinäkyvyyttä, joka korostuu kustannuslaskennan eri vaiheissa. Kustannusten läpinäkyvyys voi parantaa näiden kohdentamista sekä hallintaa. BI&A ympäristöissä myös on mahdollista käyttää erilaisia allokointimenetelmiä, mistä yleisin on toimintolaskenta (Grytz & Krohn-Grimberghe, 2018).

Uyar (2021) kertoo tutkimuksessaan BI&A työkalujen parantavan prediktiivista analysointia ja sen tarkkuutta kustannusten laskennassa, joka osaltaan parantaa ennustetarkkuutta sekä inhimillisten virheiden vähentämistä. Tutkimuksessa myös korostetaan työkalujen parantavan kustannusrakenteiden tietojen tarkennuksilla sekä tarjoamalla monipuolisempaa tietoa. BI&A työkaluilla on mahdollista yhdistää ulkoiset sekä sisäiset tietolähteet, joka osaltaan laajentaa kustannuslaskennan datapohjaa ja parantaa datan laatua. Datapohja myös voidaan rakentaa reaaliaikaiseen datan keräämiseen, joka mahdollistaa kustannuksien reaaliaikaisen analysoinnin vähentämällä viivettä ja parantamalla tarkkuutta (Uyar, 2021).

BI&A työkalujen käyttöönotossa kuitenkin nähdään suurimmat haasteet yrityksissä. Nämä työkalut ja arkkitehtuurit voivat olla monimutkaisia ja teknologian jatkuva kehitys tuovat suurempia kustannuksia. Myös monimutkaisten ohjelmistojen käyttö vaatii henkilöstöltä tarkkaa osaamista, jotta sitä käytetään tehokkaasti. Kuten data-analytiikassa

datan laatu on merkittävä tekijä myös BI&A mallit riippuvat suuresti datan laadusta. BI&A integrointi yrityksen kustannuslaskentaan vaatii suuria investointeja sekä henkilöstön kouluttamista, joka voi olla pienemmille yrityksille suurin este sen käyttöönotolle (Uyar, 2021; Grytz & Krohn-Grimberghe, 2018).

3.2 Generatiivinen tekoäly ja syväoppiminen

Generatiivinen tekoäly on kasvanut tutkimuksissa sekä yritykset yrittävät kovasti soveltaa sitä eri tarpeisiin. Kuitenkin tekoälyn hyödyntäminen on vielä alkutekijöissä johdon laskentatoimen tehtävissä, vaikka niissä nähdään suuripotentialiaali (Ranta ja muut, 2023). Generatiivinen tekoäly on tehokkaimmillaan tarjoamalla mahdollisuuksia automaation lisäämiseen, datan augmentoinnissa sekä uuden luovan sisällön tuottamisessa (Bandi ja muut, 2023).

Aiemmassa kappaleessa huomattiin data-analytiikan yhtenä suurimmista haasteina olevan monimutkaiset laskelmat sekä datan moninaisuus. Marius ja muut (2024) kertovat tutkimuksessaan generatiivisen tekoälyn avustavan monimutkaisissa datan analysointi vaiheissa. Generatiivinen tekoäly voi olla tukena datan käsittelyssä sekä tuottaa näistä raportteja, jotka ovat selkeämpiä sekä helpommin lähestyttäviä. Myös data-analyysin automatisoinnissa nähdään potentiaalia generatiivisen tekoälyn avulla (Marius ja muut, 2024, s. 134-135)

LLM:it generatiivisessa tekoälyssä ovat kykeneviä käsittelemään suuria määriä jäsentämättömiä dataa sekä tekstiä, joiden avulla ne pystyvät tuottamaan erilaisia kustannusraportteja. Ne pystyvät myös tunnistamaan keskeisiä kulueriä tehokkaasti, jotka voivat olla hankalasti nähtävillä perinteisissä järjestelmissä (Shaffer & Wang, 2024). Generatiivinen tekoäly nähdään myös mahdollisuutena käsitellä ja analysoida historiallista dataa, joka mahdollistaa prediktiivisen analysoinnin. Nämä kaikki huomioon ottaen, generatiivisen tekoälyn avulla voidaan automatisoida monimutkainen datan analysointi. Automatisointi vaikuttaa kustannuslaskennan tarkkuuteen vähentämällä inhimillisten virheiden määrää sekä nopeuttamalla laskentaa. Automatisoinnin avulla voidaan myös esimerkiksi

simuloida erilaisia tilanteita ja eri kustannusrakenteita, jotta päästäisiin tehokkaampaan lopputulokseen (Marius ja muut, 2024, s. 132-135).

Syväoppiminen ja syvät neuroverkot tukevat sekä mahdollistavat generatiivisen tekoälyn kyvyt. Syviä neuroverkkoja on käytetty rakennus- ja tuotantoprojekteissa sekä osoittautuneen tehokkaaksi työkaluksi kustannuslaskennassa ja niiden arvioimisissa. Syvät neuroverkot kykenevät käsittelemään suuria datamääriä nopeasti ja löytämään kausaalisuhteita, jotka parantavat tarkkuutta kustannusten laskennassa. Syvät neuroverkot pystyvät käsittelemään ei-lineaarisia suhteita kustannuksia laskettaessa ja parantamaan tarkkuutta, mihin perinteiset menetelmät ovat haastavia (Gusc ja muut, 2022; Sanaz ja muut, 2020). Kuitenkin syvien neuroverkkojen käsittelytulokset riippuvat suuresti datan laadusta ja määrästä, joka tuo omat haasteensa syväoppimisen käyttämisessä kustannuslaskennassa (Tayefeh Hashemi ja muut, 2020).

Generatiivisen tekoälyn sekä syväoppimisen käyttöönotto sekä käyttö kuitenkin tuovat omia haasteitaan. Marius ja muut (2024) tuovat tutkimuksessaan esille generatiivisen tekoälyn vastausten olevan joskus väärää. Tämä on kuitenkin suuresti riippuva koulutusdatan laadusta. Näitä koulutusdatoja ei ole avonaisesti nähtävillä, joten perinteiset käyttäjät eivät voi olla varmoja koulutusdatan laadusta. Grytz ja Krohn-Grimberghe (2018) kertovat artikkelissaan generatiivisen tekoälyn algoritmien olevan niin sanottuja mustia laatikoita, mikä vaikeuttaa niiden algoritmien ymmärtämistä ja tulosten oikeellisuuden tarkastamista. Generatiiviset tekoälyt eivät myöskään ole parhaimmillaan käsitteissä, sillä ne voivat sekoittaa samankaltaisia keskenään. Nämä käsitteiden väärinymmärrykset voivat johtaa kustannuslaskennan virheellisiin laskelmiin (Shaffer & Wang, 2024).

4 Yhteenveto

Tutkielmassa tarkasteltiin data-analytiikan ja generatiivisen tekoälyn vaikutuksia sekä niiden tuomia etuja ja haasteita kustannuslaskennan tarkkuuteen erityisesti vaikutukset ennustettavuuteen, tehokkuuteen sekä luotettavuuteen. Tutkielman aihe on todella ajankohtainen ja tarjoaa ymmärrystä data-analytiikan ja generatiivisen tekoälyn tuomista mahdollisuuksista. Tutkielma toteutettiin kirjallisuuskatsauksena ja pyrittiin käyttämään mahdollisimman tuoreita tieteellisiä tutkimuksia sekä artikkeleita.

Data-analytiikan ja generatiivisen tekoälyn hyödyntäminen ja integroiminen nähdään parantavan kustannuslaskennan tarkkuutta useilla eri tavoilla. Data-analytiikan monimuotoiset BI&A työkalut ja koneoppimismallit pystyvät olemaan tehokkaalla ja tarkalla tavalla suurien ja monimuotoisten data muotojen tukena. Ne parantavat analyysien tarkkuutta ja tehostavat toimintaa. Erityisesti regressioanalyysit sekä prediktiivinen analytiikka mahdollistavat kustannusten tarkempaa ennustamista ja poikkeamien tunnistamista. Koneoppimismallit ovat hyödyllisiä apuvälineitä historiallisen datan käsittelyssä sekä analysoimisessa, joiden avulla ne ovat vahvoja tunnistamaan syy-seuraussuhteita tarkemmin ja tehokkaammin verrattuna perinteisiin menetelmiin.

Generatiivisen tekoälyn vaikutus kustannuslaskennan tarkkuuteen keskittyy pääosin analysoinnin ja raportoinnin automatisoinnissa. Generatiivinen tekoäly sekä syvät neuroverkot ovat hyödyllisiä apuvälineitä data-analytiikassa, sillä ne kykenevät käsittelemään suuria määriä jäsentymätöntä dataa ja tuottaa siitä selkeitä raportteja. LLM:it pystyvät analysoimaan tarkemmin kustannusrakenteita syvemmin ja tunnistamaan merkittävät rakenteet kulujen osalta. Generatiivinen tekoäly ja LLM:it nähdään vähentävän inhimillisiä virheitä laskelmissa sekä raportoinnissa. Syvät neuroverkot ovat myös hyödyllisiä ei-lineaaristen suhteiden tunnistamisessa ja löytämään kausaliteetteja.

Data-analytiikka sekä generatiivinen tekoäly kuitenkin voivat tuoda omat haasteensa kustannuslaskennan tarkkuuteen ja ne täytyy ottaa vakavasti huomioon. Data-analytiik-

kan tai generatiivisen tekoälyn adaptoiminen kustannuslaskentaan vaatii suuria investointeja sekä osaamista. Näiden investointien sekä osaavan henkilöstön palkkaus erityisesti voi olla suurin haaste yrityksille. Data-analytiikassa sekä BI&A ohjelmistojen käytössä data sekä sen laatu on suuressa roolissa. Käsiteltävän datan laatu nähdään myös haasteena, sillä puutteellisen tai virheellisen datan avulla voidaan tehdä vääriä kustannusrakenteita tai ennusteita. Generatiivinen tekoäly on monimutkainen kokonaisuus minkä algoritmeja kuvataankin ”mustaksi laatikoksi”. Koulutusdatan läpinäkyvyys on huono ja harvoin pääseekin käsiksi niihin. Mallien läpinäkyvyyden puute voi näkyä vaikeutena tarkastaa kustannuslaskennan mallien oikeellisuuden. Generatiivisen tekoälyn mallit voivat myös sekoittaa eri käsitteitä, jolloin ne voivat viedä kustannuslaskennan päätökset virheellisiin lopputuloksiin.

Yhteenvedon voidaan todeta, että data-analytiikan työkaluilla sekä generatiivinen tekoälyllä on potentiaali parantaa tarkkuutta sekä tehokkuutta automatisoinnin kautta. Jos näitä ei integroida tarpeeksi huolellisesti kustannuslaskentaan voivat ne tuoda myös useita haasteita. Data-analytiikan sekä generatiivisen tekoälyn kanssa täytyy olla tietoinen datan laadusta, jottei se vahingoita kustannuslaskennan tarkkuutta. Data-analytiikka sekä erityisesti generatiivinen tekoäly tulevat varmasti yleistymään liiketoiminnan sekä kustannuslaskennan alueilla, joten niiden tutkiminen on tärkeässä roolissa. Jatkotutkimus aiheiksi ehdotan datan laadun vaikutus tekoälypohjaiseen kustannuslaskentaan ja kuinka paljon se todellisuudessa vaikuttaa lopputuloksiin. Ehdotan myös aiheeksi reaaliaikaisen kustannuslaskennan mahdollisuutta tekoälyn ja koneoppimisen avulla. Tämä kandidaatintyö tarjoaa jatkotutkimuksille oivallisen mahdollisuuden tutkia asiaa tarkemmin ja eri näkökulmilla.

Lähteet

- Acito, F., & Khatri, V. (2014). Business analytics: Why now and what next? *Business Horizons*, 57(5), 565–570. <https://doi.org/10.1016/j.bushor.2014.06.001>
- Askary, S., & Askarany, D. (2024). Analytical skills for accounting students in a data-driven job market: Australian evidence. *Accounting Research Journal*, 37(6), 635–654. <https://doi.org/10.1108/ARJ-05-2024-0184>
- Bandi, A., Adapa, P. V. S. R., & Kuchi, Y. E. V. P. K. (2023). The Power of Generative AI: A Review of Requirements, Models, Input–Output Formats, Evaluation Metrics, and Challenges. *Future Internet*, 15(8), 260. <https://doi.org/10.3390/fi15080260>
- Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W. (2021). Using machine learning to detect misstatements. *Review of Accounting Studies*, 26(2), 468–519. <https://doi.org/10.1007/s11142-020-09563-8>
- Cao, S. S., Jiang, W., Lei, L. (Gillian), & Zhou, Q. (Clara). (2024). Applied AI for finance and accounting: Alternative data and opportunities. *Pacific-Basin Finance Journal*, 84, 102307. <https://doi.org/10.1016/j.pacfin.2024.102307>
- Chen, Chiang, & Storey. (2012). Business Intelligence and Analytics: From Big Data to Big Impact. *MIS Quarterly*, 36(4), 1165. <https://doi.org/10.2307/41703503>
- Cohen, S., & Kaimenaki, E. (2011). Cost accounting systems structure and information quality properties: An empirical analysis. *Journal of Applied Accounting Research*, 12(1), 5–25. <https://doi.org/10.1108/09675421111130586>
- De Mauro, A., Greco, M., & Grimaldi, M. (2016). A formal definition of Big Data based on its essential features. *Library Review*, 65(3), 122–135. <https://doi.org/10.1108/LR-06-2015-0061>

- Deng, X., & Chi, L. (2012). Understanding Postadoptive Behaviors in Information Systems Use: A Longitudinal Analysis of System Use Problems in the Business Intelligence Context. *Journal of Management Information Systems*, 29(3), 291–326. <https://doi.org/10.2753/MIS0742-1222290309>
- Deniswara, K., Leo Handoko, B., & Mulyawan, A. N. (2020). BIG DATA ANALYTICS: LITERATURE STUDY ON HOW BIG DATA WORKS TOWARDS ACCOUNTANT MILLENNIAL GENERATION. *IAEME*, 11(5), 376–389. <https://doi.org/10.34218/IJM.11.5.2020.037>
- Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2024). Generative AI. *Business & Information Systems Engineering*, 66(1), 111–126. <https://doi.org/10.1007/s12599-023-00834-7>
- Ghasemaghaei, M. (2020). The role of positive and negative valence factors on the impact of bigness of data on big data analytics usage. *International Journal of Information Management*, 50, 395–404. <https://doi.org/10.1016/j.ijinfomgt.2018.12.011>
- Goldman Sachs. (2023, huhtikuuta 5). *Generative AI could raise global GDP by 7%*. <https://www.goldmansachs.com/insights/articles/generative-ai-could-raise-global-gdp-by-7-percent.html>
- Gusc, J., Bosma, P., Jarka, S., & Biernat-Jarka, A. (2022). The Big Data, Artificial Intelligence, and Blockchain in True Cost Accounting for Energy Transition in Europe. *Energies*, 15(3), 1089. <https://doi.org/10.3390/en15031089>
- Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5–14. <https://doi.org/10.1177/0008125619864925>

- Hesford, J. W., Pizzini, M., & Turner, M. J. (2024). Incorporating Data Analytics in Management Accounting: A Teaching Case on Cost Estimation. *Issues in Accounting Education*, 39(2), 133–149. <https://doi.org/10.2308/ISSUES-2022-064>
- Horngren, C. T., Datar, S. M., & Rajan, M. V. (2015). *Cost accounting: A managerial emphasis* (15. ed., global ed). Pearson Education Limited.
- Ikäheimo, S., Malmi, T., & Walden, R. (2019). *Yrityksen Laskentatoimi* (8., uudistettu painos). Alma Talent Oy ja tekijät. [https://verkkokirjahylly-almatalent-fi.proxy.uwasa.fi/teos/JACBIXDTEB#kohta:YRITYKSEN\(\(20\)LASKENTA-TOIMI\(\(20\)/piste:b4](https://verkkokirjahylly-almatalent-fi.proxy.uwasa.fi/teos/JACBIXDTEB#kohta:YRITYKSEN((20)LASKENTA-TOIMI((20)/piste:b4)
- Jeyanthi, P. M., Choudhury, T., Hack-Polay, D., Singh, T. P., & Abujar, S. (Toim.). (2022). *Decision Intelligence Analytics and the Implementation of Strategic Business Management*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-82763-2>
- Järvenpää, M., Länsiluoto, A., Partanen, V., & Pellinen, J. (2017). *Talousohjaus ja kustannuslaskenta* (2.-4.painos). Sanoma Pro Oy. <https://www.ellibslibrary.com/book/978-952-63-2005-2>
- Kalyan, K. S. (2024). A survey of GPT-3 family large language models including ChatGPT and GPT-4. *Natural Language Processing Journal*, 6, 100048. <https://doi.org/10.1016/j.nlp.2023.100048>
- Kashyap, R. (2019). Big Data Analytics Challenges and Solutions. Teoksessa *Big Data Analytics for Intelligent Healthcare Management* (ss. 19–41). Elsevier. <https://doi.org/10.1016/B978-0-12-818146-1.00002-7>
- Knox, B. D. (2023). Machine Learning Activity-Based Costing: Can Activity-Based Costing's First-Stage Allocation Be Replaced with a Neural Network? *Journal of*

- Emerging Technologies in Accounting*, 20(2), 95–117.
<https://doi.org/10.2308/JETA-2021-046>
- Kohli, S. L. (2009). *Professional Cost Accounting*. Global Media.
- Laitinen, E. K. (2014). Influence of cost accounting change on performance of manufacturing firms. *Advances in Accounting*, 30(1), 230–240.
<https://doi.org/10.1016/j.adiac.2014.03.003>
- Lim, E.-P., Chen, H., & Chen, G. (2013). Business Intelligence and Analytics: Research Directions. *ACM Transactions on Management Information Systems*, 3(4), 1–10.
<https://doi.org/10.1145/2407740.2407741>
- Lukka, K., & Granlund, M. (1996). Cost accounting in Finland: Current practice and trends of development. *European Accounting Review*, 5(1), 1–28.
<https://doi.org/10.1080/09638189600000001>
- M, S. B., & A, G. (2017). A Survey on Data Analytics Framework. *International Journal of Engineering and Technology*, 9(3), 1650–1656.
<https://doi.org/10.21817/ijet/2017/v9i3/170903010>
- Ojanperä, T. (2023). *Tekoälyn vallankumous*. Alma talent. [https://bisneskirjasto-almatalent-fi.proxy.uwasa.fi/teos/CAHBBXXT-BBAEF#/kohta:Teko\(\(e4\)lyn\(\(20\)vallankumous/piste:thI](https://bisneskirjasto-almatalent-fi.proxy.uwasa.fi/teos/CAHBBXXT-BBAEF#/kohta:Teko((e4)lyn((20)vallankumous/piste:thI)
- Pellinen, J. (2019). *Kustannuslaskenta ja kannattavuusajattelu*. [https://verkkokirjahylly-almatalent-fi.proxy.uwasa.fi/teos/IAI-BFXDTEB#kohta:3\(\(20\)Tuotanto\(\(20\)ja\(\(20\)p\(\(e4\)\(\(e4\)t\(\(f6\)ksenteko\(:3.1\(\(20\)Tuotanto/piste:t5Au](https://verkkokirjahylly-almatalent-fi.proxy.uwasa.fi/teos/IAI-BFXDTEB#kohta:3((20)Tuotanto((20)ja((20)p((e4)((e4)t((f6)ksenteko(:3.1((20)Tuotanto/piste:t5Au)
- Pence, H. E. (2014a). What is Big Data and Why is it Important? *Journal of Educational Technology Systems*, 43(2), 159–171. <https://doi.org/10.2190/ET.43.2.d>

- Pence, H. E. (2014b). What is Big Data and Why is it Important? *Journal of Educational Technology Systems*, 43(2), 159–171. <https://doi.org/10.2190/ET.43.2.d>
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M. P., Shyu, M.-L., Chen, S.-C., & Iyengar, S. S. (2019). A Survey on Deep Learning: Algorithms, Techniques, and Applications. *ACM Computing Surveys*, 51(5), 1–36. <https://doi.org/10.1145/3234150>
- Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking* (First edition). O'Reilly.
- Ranta, M., Ylinen, M., & Järvenpää, M. (2023). Machine Learning in Management Accounting Research: Literature Review and Pathways for the Future. *European Accounting Review*, 32(3), 607–636. <https://doi.org/10.1080/09638180.2022.2137221>
- Rikhardsson, P., & Yigitbasioglu, O. (2018). Business intelligence & analytics in management accounting research: Status and future focus. *International Journal of Accounting Information Systems*, 29, 37–58. <https://doi.org/10.1016/j.acinf.2018.03.001>
- Sharma, P., Kumar, M., Sharma, H. K., & Biju, S. M. (2024). Generative adversarial networks (GANs): Introduction, Taxonomy, Variants, Limitations, and Applications. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-024-18767-y>
- Shum, H., He, X., & Li, D. (2018). From Eliza to XiaoIce: Challenges and opportunities with social chatbots. *Frontiers of Information Technology & Electronic Engineering*, 19(1), 10–26. <https://doi.org/10.1631/FITEE.1700826>

- Silahtaroglu, G., & Alayoglu, N. (2016). Using or Not Using Business Intelligence and Big Data for Strategic Management: An Empirical Study Based on Interviews with Executives in Various Sectors. *Procedia - Social and Behavioral Sciences*, 235, 208–215. <https://doi.org/10.1016/j.sbspro.2016.11.016>
- Sætra, H. S. (2023). Generative AI: Here to stay, but for good? *Technology in Society*, 75, 102372. <https://doi.org/10.1016/j.techsoc.2023.102372>
- Tayefeh Hashemi, S., Ebadati, O. M., & Kaur, H. (2020). Cost estimation and prediction in construction projects: A systematic review on machine learning techniques. *SN Applied Sciences*, 2(10), 1703. <https://doi.org/10.1007/s42452-020-03497-1>
- Uyar, M. (2021). The Role of Business Analytics in Transforming Management Accounting Information into Cost Performance. *Ege Akademik Bakis (Ege Academic Review)*, 373–389. <https://doi.org/10.21121/eab.1015665>
- Wu, Y., & Feng, J. (2018). Development and Application of Artificial Neural Network. *Wireless Personal Communications*, 102(2), 1645–1656. <https://doi.org/10.1007/s11277-017-5224-x>
- Yazici, İ., Shayea, I., & Din, J. (2023). A survey of applications of artificial intelligence and machine learning in future mobile networks-enabled systems. *Engineering Science and Technology, an International Journal*, 44, 101455. <https://doi.org/10.1016/j.jestch.2023.101455>
- Yusuf, A., Pervin, N., Román-González, M., & Noor, N. M. (2024). Generative AI in education and research: A systematic mapping review. *Review of Education*, 12(2), e3489. <https://doi.org/10.1002/rev3.3489>

Zhang, J., Niu, L., & Li, Z. (2020). A Brief Analysis on the Application and Influence of Computer Big Data in Management Accounting. *Journal of Physics: Conference Series*, 1648(2), 022098. <https://doi.org/10.1088/1742-6596/1648/2/022098>