



Vaasan yliopisto
UNIVERSITY OF VAASA

Kalle Palomäki

**Data-analytiikalla säästöä hankinnoista –
Skenaarioanalyysi case-yrityksen epäsuorien
hankintojen kehityksestä 2025–2034**

Laskentatoimen ja rahoituksen
akateeminen yksikkö
Laskentatoimen ja tilintarkastuksen pro
gradu -tutkielma
Laskentatoimen ja tilintarkastuksen
maisteriohjelma

Vaasa 2025

VAASAN YLIOPISTO**Laskentatoimen ja rahoituksen akateeminen yksikkö**

Tekijä:	Kalle Palomäki		
Tutkielman nimi:	Data-analytiikalla säästöä hankinnoista – Skenaarioanalyysi case-yrityksen epäsuorien hankintojen kehityksestä 2025–2034		
Tutkinto:	Kauppätieteiden maisteri		
Oppiaine:	Laskentatoimen ja tilintarkastuksen maisteriohjelma		
Työn ohjaaja:	Mikko Ranta		
Valmistumisvuosi:	2025	Sivumäärä:	108

TIIVISTELMÄ:

Edellisen vuoden, kuukauden, viikon ja päivän tapahtumat ovat historiaa, eikä yritysten tuotama menneeseen aikaan perustuva raportointi voi niitä muuttaa. Jotta yritykset pysyvät kilpailukyysisinä, on niiden pohdittava tulevaisuuttaan. Nykyajan liiketoiminnassa vain muutos on pysyvää, minkä vuoksi raportoinnin ja yrityksen johdon toiminnan tulisi keskittyä entistä enemmän ennakoivaan suuntaan. Data-analytiikan osa-alueen ennakoivan analytiikan avulla yritykset voivat mallintaa tulevaisuuden tapahtumia. Tutkimuksen case-yrityksessä ei ollut aiemmin ennakoitu ennakoivia menetelmiä hyödyntäen pitkän aikavälin tapahtumia, minkä vuoksi tutkimuskohteeksi valikoitui skenaarioanalyysi epäsuorien hankintojen kehityksestä kymmenen vuoden ajanjaksolla 2025–2034. Epäsuorien hankintojen merkitys liiketoiminnan strategisena tekijänä on kasvanut viime vuosina, joten niiden kehityksen ennakoiminen nähtiin mielenkiintoisena tutkimuskohteena. Myös hankinnoista saatavien mahdollisten kustannussäästöjen havaitseminen data-analytiikan avulla nähtiin kiinnostavana, mitä lähdettiin selvittämään kirjallisuuskatsauksella aiemmista tutkimuksista.

Tutkimusta voidaan pitää tutkimusotteeltaan konstruktiiivisena, jossa hyödynnetään sekä kvalitatiivisia että kvantitatiivisia menetelmiä. Tutkimuksessa luotiin case-yritykselle neljä skenaariota epäsuorien hankintojen kehityksestä. Ennakoivassa mallintamisessa hyödynnettiin case-yrityksen epäsuorien hankintojen dataa vuosilta 2020–2024, mikä kerättiin case-yrityksen järjestelmistä. Tutkimuksessa tekoälyn, Python-ohjelmointikielen ja Excelin avulla rakennettuun ennakoivaan laskentamalliin hyödynnettiin trendivaikutteista TIA-menetelmää (trend impact analysis). Tutkimuksen case-yritykselle luotiin PESTEL-analyysi, jolla tunnistettiin liiketoimintaympäristön ulkoisia tekijöitä, ja niiden pohjalta tarkennettiin skenaarioiden taustaolettamuksia. PESTEL-analyysin tuloksista voidaan todeta, että case-yrityksen ja yleisesti autoalan toimintaan vaikuttavat vahvasti ekologiset sekä poliittiset päätökset nyt ja tulevaisuudessa. Suomen autokannan on sähköistyttävä, mikäli liikenteen päästövähennystavoitteet halutaan saavuttaa.

Tutkimustulokset osoittavat data-analytiikan käytön hankintojen hallinnassa saavuttavan jopa merkittäviä kustannussäästöjä, mutta se vaatii sekä edistyneitä analytiikkatyökaluja että vahvaa IT-osaamista. Ennakoivan ja ohjaavan analytiikan nähdään kasvattavan suosiotaan, kun tekoälyn kehittymisen myötä vaativien mallien luominen ei vaadi välttämättä aiempaa koodauskokemusta tai -koulutusta. Tutkimuksessa rakennettu laskentamalli ja sen kautta johdetut skenaariot tuovat case-yritykselle hyötyä päätöksentekoon, varsinkin pitkällä aikavälillä epäsuorien hankintojen osalta. Mikäli case-yrityksen toimintaa halutaan muuttaa entistä tulevaisuusorientoituneempaan suuntaan, on sen todennäköisesti luotava tiimi tulevaisuustyölle.

AVAINSANAT: Skenaarioanalyysi, data-analytiikka, epäsuorat hankinnat, autoala, ennakoiva mallinnus

Sisällys

1	Johdanto	6
1.1	Tutkimuksen tavoite ja tutkimuskysymykset	7
1.2	Tutkimuksen rajaukset	8
1.3	Tutkimuksen rakenne	9
2	Epäsuorat hankinnat	11
2.1	Hankintojen hallintastrategiat	12
2.2	Epäsuorien hankintojen rooli taloudellisessa suorituskyvyssä	17
3	Data-analytiikka	20
3.1	Datan määritelmä	21
3.2	Data-analytiikan tasot	24
3.2.1	Selittävä analytiikka	25
3.2.2	Ennakoiva analytiikka	26
3.2.3	Kuvaileva analytiikka	27
3.2.4	Ohjaava analytiikka	28
3.3	Data-analytiikan rooli hankintojen kustannussäästöissä	29
4	Skenaarioanalyysi	34
4.1	Skenaarion määritelmä	35
4.2	Skenaarioanalyysi suunnittelumenetelmänä	38
4.2.1	Skenaarioanalyysin vaiheet	41
4.2.2	Työkaluja skenaarioanalyysin muodostamiseen	43
4.3	Datan rooli tulevaisuudentutkimuksessa	48
4.3.1	Datan käyttö skenaarioiden rakentamisessa	49
4.3.2	Skenaarioita datan hyödyntämisestä tulevaisuudessa	53
5	Case-yrityksen toimiala	55
5.1	Yleistä autoalasta ja -markkinasta	55
5.2	Case-yrityksen epäsuorat hankinnat	57
6	Tutkimusmenetelmät ja aineisto	59
6.1	PESTEL-analyysi	63

6.1.1	Poliittiset tekijät	64
6.1.2	Ekonomiset tekijät	65
6.1.3	Sosiaaliset tekijät	66
6.1.4	Teknologiset tekijät	67
6.1.5	Ekologiset tekijät	68
6.1.6	Lainsäädännölliset tekijät	69
6.2	TIA-menetelmä	70
6.3	Laskentamallin laadinta	71
6.4	Skenaarioanalyysi ja skenaarioiden vaikutus päätöksentekoon	74
6.4.1	Perusskenaario	75
6.4.2	Taloukasvuskenaario	77
6.4.3	Taantumaskenaario	79
6.4.4	Sähkö-Suomi-skenaario	81
6.4.5	Skenaarioiden rooli päätöksenteossa	83
7	Yhteenveto ja johtopäätökset	86
7.1	Yhteenveto	86
7.2	Johtopäätökset	87
7.3	Jatkotutkimusehdotukset	90
	Lähteet	93
	Liitteet	105
	Liite 1. PESTEL-analyysi case-yrityksen toimintaympäristöstä	105
	Liite 2. Skenaarioiden taustaolettamukset	107

Kuvat

Kuva 1. Henkilöautokannan sähköistymiskehitys Pohjoismaissa vuosina 2019–2024.	57
Kuva 2. Pythonilla luotu Monte Carlo -simulaatio kolikonheiton yhteydessä.	73

Kuviot

Kuvio 1. Kraljicin matriisi.	13
Kuvio 2. Tiedon jalostuminen.	21
Kuvio 3. Data-analytiikan tasot.	25
Kuvio 4. Konstruktivinen tutkimusote metodologiana.	60
Kuvio 5. CRISP-DM malli.	62
Kuvio 6. Epäsuorien hankintojen kehitys perusskenaariossa.	75
Kuvio 7. Epäsuorien hankintojen kehitys talouskasvuskenaariossa.	77
Kuvio 8. Epäsuorien hankintojen kehitys taantumaskenaariossa.	79
Kuvio 9. Epäsuorien hankintojen kehitys sähkö-Suomi-skenaariossa.	81

1 Johdanto

Globalisoituneessa yritysmaailmassa muutoksia tapahtuu jatkuvasti. Organisaatioiden on tehtävä päätöksiä tehokkaammin tulevaisuuden epävarmuustekijöiden ollessa entistä ajankohtaisempia. Strateginen suunnittelu on yksi avaintekijöistä, jotta liiketoiminta pysyy muutoskykyisenä (Hammoud & Nash, 2014). Yritykset eivät voi enää vain katsoa taustapeilistä tapahtuneita asioita, vaan niiden on oltava aktiivisia tulevaisuuden tapahtumien ennakoinnissa. Tulevaisuuden ollessa epävarmaa, muuttuu päätöksenteko haastavammaksi. Varsinkin jatkuvasti lisääntyvän datan myötä organisaatioiden on pohdittava, mikä data on hyödyllistä ja mikä ei.

Vaikka tarkkaa tulevaisuuden suuntaa on mahdoton ennustaa, on tulevaisuuteen vaikuttavien mahdollisten tekijöiden tutkiminen kuitenkin mahdollista. Esimerkiksi teknologian kehitys, ympäristön muutokset, yhteiskunnalliset rakenteet ja taloudelliset suuntauksukset ovat kaikki tekijöitä, jotka voivat vaikuttaa siihen, millaiseksi maailma kehittyy. Ihmiset siis määrittävät tulevaisuuden omilla valinnoillaan (Mannermaa, 1999).

Ennakoivien mallien ja skenaarioiden avulla voidaan hahmotella mahdollisia tulevaisuuden polkuja ja valmistautua niihin mahdollisimman hyvin. Oliverin ja Parretin (2018) mukaan tulevaisuus on sekä ongelma että mahdollisuus, jota organisaation päätöksenteko ei voi välttää. He toteavat tulevaisuuskuvien eli skenaarioiden olevan strateginen ennustamisväline, joka on jo kauan nähty yhtenä mahdollisista puolustustoimista ennalta arvaamatonta tulevaisuutta vastaan. Pitkälle tulevaisuuteen ennustaminen on mahdollista, mutta tuleviin mahdollisiin muutoksiin ennakointi täysin mahdollista.

Hankintatoiminta on liiketoiminnan yksi osa-alue, joka vaikuttaa merkittävästi yrityksen kustannusrakenteeseen, operatiiviseen tehokkuuteen ja kilpailukykyyn. Hankintoja voidaan luokitella suoriin ja epäsuoriin hankintoihin, joista jälkimmäiset liittyvät tuotteisiin ja palveluihin, jotka eivät suoraan liity yrityksen lopputuotteeseen, mutta ovat välttämättömiä liiketoiminnan sujuvuuden kannalta (Millington, 2021). Vaikka epäsuorat

hankinnat voivat muodostaa merkittävän osan yrityksen kokonaiskuluista, niiden hallinta jää usein vähemmälle huomiolle kuin suorien hankintojen.

Digitalisaation ja data-analytiikan kehittyminen tarjoavat uusia mahdollisuuksia optimoida epäsuoria hankintoja ja parantaa niiden hallintaa (Payne & muut, 2021). Epäsuorat hankinnat nähdään myös tulevaisuudessa merkittävänä kuluina yritysten toiminnassa erityisesti generatiivisen tekoälyn ja ennakoivan analytiikan kehittymisen myötä (KPMG, 2024). Tämän tutkimuksen tarkoituksena on tutkia, miten data-analytiikan avulla voidaan saavuttaa säästöjä epäsuorissa hankinnoissa ja mitä tulevaisuuden skenaarioita voidaan rakentaa vuosille 2025–2034.

1.1 Tutkimuksen tavoite ja tutkimuskysymykset

Case-yrityksessä tulevaisuuden ennustamista ei ole aiemmin tehty aktiivisesti pitkällä aikavälillä. Monissa liiketoiminnan osa-alueissa, kuten epäsuorissa hankinnoissa nähdään optimointipotentiaalia data-analytiikan ja tekoälyn yleistyessä. Tutkimuksen tavoitteena on selvittää, miten data-analytiikkaa voidaan hyödyntää epäsuorien hankintojen optimoinnissa. Skenaarioanalyysi pohjautuu tutkimuksen yhteydessä luotuun laskentamalliin, jonka avulla voidaan luoda vaihtoehtoisia kehityspolkuja yrityksen epäsuorien hankintojen kehittymisestä vuoteen 2034. Skenaarioiden tueksi pyritään havaitsemaan keskeisiä liiketoiminnan ulkoisia tekijöitä, jotka vaikuttavat epäsuoriin hankintoihin. Tutkimuksessa edellä mainittuja seikkoja lähestytään kolmen tutkimuskysymyksen kautta:

1. Miten data-analytiikkaa voidaan soveltaa hankintojen tutkinnassa?
2. Mitkä ovat tärkeimmät ulkoiset tekijät, jotka vaikuttavat case-yrityksen epäsuorien hankintojen hintakehitykseen vuosina 2025–2034?
3. Voiko case-yritys saada skenaarioanalyysillä tukea strategiseen päätöksentekoon sekä epäsuorien hankintojen ennakointiin?

Näiden kolmen tutkimuskysymyksen kautta odotetaan saatavan vastaukset tutkielman tavoitteisiin. Tutkielman teoreettinen viitekehys rakennetaan tutkimuskysymysten perusteella. Teoriaosassa käsitellään aihealueen kolme keskeisintä käsitettä: epäsuoria hankintoja, data-analytiikkaa ja skenaarioanalyysiä.

Tutkimuksessa hyödynnetään sekä kvantitatiivisia että kvalitatiivisia menetelmiä. Se on yleistä case-tutkimuksessa, ja takaa usein parhaan tutkimustuloksen (Yin, 2009). Skenaarioiden tueksi laadittavat ulkoiset tekijät saadaan PESTEL-analyysin avulla, jota voidaan pitää kvalitatiivisena analyysinä. Case-yritykselle rakennettu laskentamalli hyödyntää TIA-menetelmää, jota voidaan pitää sekä kvalitatiivisena että kvantitatiivisena menetelmänä. Edellä mainitut analyysit luodaan luvuissa 6.1 ja 6.2. Kvantitatiivinen lähestymistapa nousee esiin laskentamallin yhteydessä, jossa hyödynnetään case-yrityksen järjestelmistä saatavaa numeerista dataa.

1.2 Tutkimuksen rajaukset

Skenaariot pyritään koskemaan jotain tiettyä vuotta (Mannermaa, 1999). Tulevaisuuskuvioiden luominen seuraavalle kymmenelle vuodelle on melko tyyppillistä, joten tässä tutkimuksessa skenaariot rajataan koskemaan vuotta 2034. Tavoitteena on tutkia, mitkä tekijät vaikuttavat epäsuorien hankintojen hintakehitykseen vuodesta 2025 vuoteen 2034.

Skenaarioanalyysi johdetaan kolmesta eri skenaariosta ja myös yhdestä puhtaasti historiatietoon perustuvasta perusskenaariosta. Ei ole olemassa yhtä oikeaa vastausta siihen, kuinka monta skenaariota on paras määrä. Mannermaa (1999, s. 66) pitää kolmesta viiteen skenaariota optimaalisena. Skenaarioita olisi hyvä olla ainakin kolme, jotta olisi monta vaihtoehtoa tarjolla: kaksi skenaariota on liian vähän, sillä silloin usein ilmenetään vain hyvä ja huono skenaario. Toisaalta skenaarioiden hallinta ja koko skenaarioanalyysin teko vaikeutuu, jos skenaarioita on liian monta. Edellä mainittujen seikkojen takia tähän tutkimukseen mallinnetaan neljä skenaariota.

Pro gradu -tutkielma on julkinen opinnäytetyö, joten liikesalaisuuksia sisältävät tiedot eivät julkistetussa versiossa vastaa case-yrityksen todellisia arvoja. Tutkimuksessa esitetyt skenaariot perustuvat mahdollisiin kehityssuuntiin ja tarjoavat suuntaa antavaa tietoa case-yritykselle. Case-yritykselle toimitettava sisäinen versio poikkeaa julkisesta versiosta sisällön osalta.

1.3 Tutkimuksen rakenne

Tämä tutkimus koostuu seitsemästä pääluvusta. Ensimmäinen luku sisältää johdannon aiheeseen, jossa käsitellään tulevaisuuden epävarmuuden tilan karttamista analytiikan keinoin. Johdannossa esitetään myös tutkimuksen tavoite sekä kolme tutkimuskysymystä. Niiden lisäksi määritetään tutkimuksen aihealueen rajaus.

Toisessa luvussa käsitellään epäsuoria hankintoja. Siinä tarkastellaan epäsuorien hankintojen käsitettä, hankintojen hallintastrategioita sekä epäsuorien hankintojen merkitystä yrityksen taloudelliselle suorituskyvylle. Luku syventää ymmärrystä siitä, miksi epäsuorien hankintojen optimointi on tärkeää. Kolmannessa luvussa paneudutaan data-analytiikkaan. Luvussa käsitellään datan määritelmää, data-analytiikan tasoja sekä niiden roolia mahdollisten kustannussäästöjen havainnoinnissa. Nämä työkalut tarjoavat pohjan tutkimuksen laskentamallin ja skenaarioanalyysin laadinnalle. Neljännessä luvussa esitellään skenaarioanalyysi suunnittelumenetelmänä, kuvataan sen vaiheita sekä esitellään työkalut ja hyödyt, joita skenaarioanalyysin käyttäminen voi tarjota. Lisäksi tuodaan esille aiempia tutkimuksia skenaarioanalyyseistä.

Viidennessä luvussa esitetään case-yrityksen toimintaympäristöä ja markkinoita. Osiossa annetaan yleiskuva autoalasta Suomessa ja case-yrityksen epäsuorat hankinnat jaetaan neljään osaan. Kuudennessa luvussa esitellään tutkimuksen empiirisen osan toteutus, jossa laaditaan laskentamalli, PESTEL- ja skenaarioanalyysi. Luvussa arvioidaan myös skenaarioiden vaikutusta päätöksentekoon. Viimeisessä luvussa tuodaan esiin tutkimuksen

keskeisimmät löydökset ja niiden merkitys case-yritykselle sekä esitetään tutkimukselle jatkotutkimusehdotuksia.

2 Epäsuorat hankinnat

Yritysten liiketoiminta koostuu tuotoista ja kuluista. Jokainen yritys tarvitsee resursseja toimintansa ylläpitämiseksi. Vaikka yrityksen tulos syntyy myynnistä, niin kulujen hallinnan vaikutusta liiketoiminnan kannattavuuteen ei pidä aliarvioida. Paynen ja muiden (2021) mukaan kulujen optimointi voi vaikuttaa tulokseen yhtä merkittävästi kuin myynnin kasvattaminen. Myynnillä saadaan liiketoimintaan kasvua ja kulujen hallinnalla voittoa.

Millingtonin (2021) mukaan yritysten hankinnat jakautuvat kahteen kategoriaan: suoriin hankintoihin ja epäsuoriin hankintoihin. Suorilla hankinnoilla tarkoitetaan materiaaleja, raaka-aineita ja palveluita, jotka liittyvät suoraan yrityksen tuotteen tai palvelun valmistamiseen. Epäsuorat hankinnat puolestaan viittaavat tuotteisiin ja palveluihin, jotka eivät suoraan liity myytävän tuotteen valmistamiseen, mutta ovat välttämättömiä yrityksen päivittäisen toiminnan ylläpitämiseksi. Epäsuoria hankintoja ovat muun muassa:

1. IT-tarvikkeet ja -ohjelmistot
2. Kiinteistöjen ylläpito, kuten siivous- ja vartiointipalvelut
3. Toimistotarvikkeet ja -laitteet
4. Markkinointi- ja viestintäpalvelut
5. Logistiikka- ja kuljetuspalvelut

Epäsuorat hankinnat ovat usein johtamatonta ja laajalle hajautunutta ostotoimintaa, mikä vaikeuttaa säästömahdollisuuksien havaitsemista ja hyödyntämistä (Iloranta & Pajunen-Muhonen, 2018, s. 62–64). Silloin ostaminen muodostuu helposti koordinoimattomaksi toiminnaksi, jossa organisaation eri osa-alueilla toimitaan omien mieltymysten mukaan budjetin rajoissa. Niin sanotun villin ostamisen suurin ongelma on se, että kenelläkään ei ole kokonaisymmärrystä siitä, mitä kaikkea hankitaan ja millaisilla summilla.

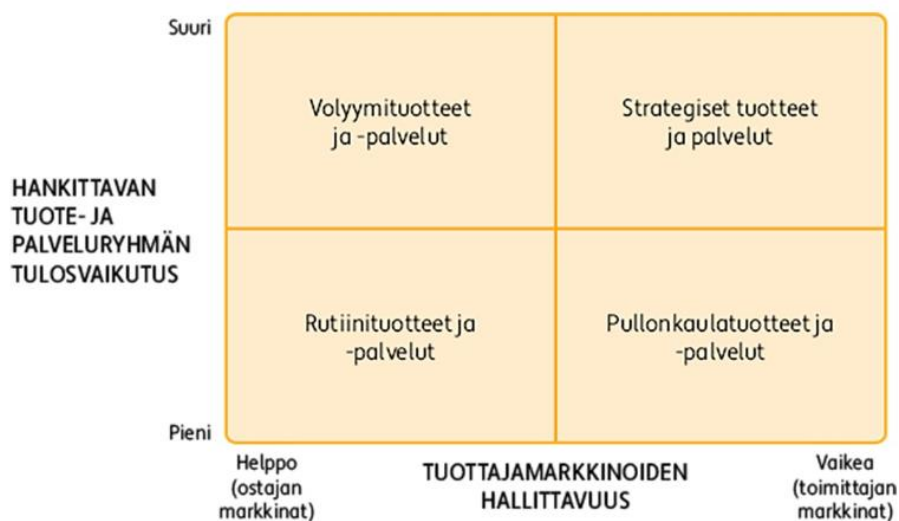
Epäsuorien hankintojen merkitys yrityksen toiminnassa on kasvanut viime vuosina digitalisaation, kestävän kehityksen sekä teknologisen kehityksen myötä (KPMG, 2024). Yhä

useammat organisaatiot pyrkivät optimoimaan hankintojaan paitsi kustannussäästöjen saavuttamiseksi, myös operatiivisen tehokkuuden parantamiseksi. Vaikka epäsuorat hankinnat eivät kosketa suoraan myytävää tuotetta tai palvelua, niiden osuus yrityksen kokonaiskuluista voi olla merkittävä, erityisesti suurissa organisaatioissa. Esimerkiksi palvelualalla, jossa fyysisiä tuotteita valmistetaan vähän, epäsuorat hankinnat voivat jopa dominoida kustannusrakennetta. Täten niiden hallinta on tärkeää niin yrityksen selviytymisen kuin menestymisenkin kannalta.

2.1 Hankintojen hallintastrategiat

Organisaation on ymmärrettävä hankintojensa nykytila, jotta niitä voidaan kehittää. Tärkeä lähtökohta on kartoittaa kaikki hankinnat spend-analyysillä, jossa havainnollistetaan mitä ostetaan, miltä toimittajilta ja millä hinnalla (Iloranta & Pajunen-Muhonen, 2018, s. 104). Tämän jälkeen hankinnat tulisi segmentoida osiin, jotta organisaatio voi hallita hankintojen kokonaisuutta entistä paremmin. Looginen segmentointi auttaa hankintojen hallintastrategian luonnissa. Segmentointi voidaan luoda esimerkiksi taloudellisen merkityksen tai toimittajien mukaan (Iloranta & Pajunen-Muhonen, 2018, s. 107–112).

Vuorisen ja Huikkolan (2023) mukaan tunnetuin hankintojen hallintastrategia on Peter Kraljicin vuonna 1983 kehittämä Kraljicin matriisi, jossa hankittavat palvelut ja tuotteet luokitellaan niiden tulosvaikutusmerkityksen ja toimittajamarkkinan monimutkaisuuden perusteella. Kraljicin nelikentässä hankinnat ovat keskenään hyvin erilaisia, minkä perusteella ne luokitellaan volyyymi-, rutiini-, pullonkaula- ja strategisiin hankintoihin. Kuviossa 1 esitetään Kraljicin matriisissa tuotteiden ja palveluiden ryhmittely.



Kuvio 1. Kraljicin matriisi. (Vuorinen & Huikkola, 2023)

Toimittajien hallittavuuden osalta ostavan yhtiön tilanne on ihanteellinen volyymi- ja rutiinihankinnoissa. Volyymihankinnat ovat tyypillisesti rahallisesti merkittävimpiä, sillä niissä ostomäärät ovat suuria. Organisaatio voi hyödyntää skaalaetuja, aggressiivista kilpailuttamista ja neuvotteluvoimaa toimittajien kanssa. Volyymihankintoihin panostamalla yritys voi saada huomattavia kustannussäästöjä sekä kilpailuetua. Rutiinihankinnat puolestaan ovat usein arvoltaan pieniä ja helposti saatavilla useilta toimittajilta. Esimerkiksi kiinteistön ylläpitosiivous tai uusille työntekijöille hankittavat tietokoneet ja puhelimet voivat olla rutiinihankintoja. Toimittajasuhteiden ylläpito ei vaadi syvällistä ylläpitoa. Näissä hankinnoissa hankintaprosessi voidaan automatisoida tai ulkoistaa, sillä prosessi voi aiheuttaa paljon kustannuksia hankinnan arvoon verrattuna. Esimerkiksi toimistotarvikkeita kannattaa hankkia kerralla paljon, ettei ylimääräinen hallinnollinen taakka syö kustannushyötyä. (Iloranta & Pajunen-Muhonen, 2018, s. 119–120; Vuorinen & Huikkola, 2023)

Ostavan yhtiön on haastavaa hallita toimittajia pullonkaula- ja strategisissa hankinnoissa. Pullonkaulahankinnoiksi kutsutaan hankintoja, joita voi olla markkinoilla niukasti saatavilla. Vaikka niiden arvo on pieni, niiden puuttuminen voi aiheuttaa toiminnan ongelmia. Tällaisissa hankinnoissa markkinoilla voi olla vain yksi toimittaja, jolloin suhde

toimittajaan on kriittinen. Ostavalla yrityksellä on olemattomat mahdollisuudet hintaneuvotteluihin ja riippuvuus toimittajaa kohtaan on suuri. Sama tilanne on usein strategisten hankintojen kanssa. Ne ovat rahallisesti suuria hankintoja, joissa markkinoilla valitsee vain muutamia toimittajia. Ostavan yrityksen kilpailukyky voi olla riippuvainen strategisista hankinnoista, minkä vuoksi on tärkeää luoda syvälinen luottamus toimittajiin. Lentokoneen moottori on esimerkki strategisesta hankinnasta, sillä ne ovat kriittisiä sekä suorituskyvyn että turvallisuuden kannalta. (Iloranta & Pajunen-Muhonen, 2018, s. 121–122; Vuorinen & Huikkola, 2023)

Epäsuorien hankintojen hallinta on olennainen osa yrityksen strategista hankintatoimintaa. Vaikka epäsuorat hankinnat eivät liity suoraan yrityksen myytävään tuotteeseen, niin niiden tehokas hallinta on keskeistä operatiivisen tehokkuuden, kustannussäästöjen ja kilpailukyvyn parantamisessa. Epäsuorat hankinnat muodostavat usein merkittävän osan yrityksen kokonaiskuluista, kuten myös tutkimuksen case-yrityksessä. Epäsuorien hankintojen hallintastrategioiden valinnalla voi olla huomattava vaikutus yrityksen taloudelliseen tulokseen (Nair & muut, 2015).

Case-yrityksessä epäsuorilla hankinnoilla on huomattavasti enemmän toimittajia suoriin hankintoihin verrattuna. Ne ovat usein hajautettuja ja niihin liittyviä kuluja voi olla vaikea havaita. Sen vuoksi kokonaiskuvan saaminen epäsuorista kustannuksista voi olla haastavaa. Epäsuorien hankintojen hajanaisuus tekee niiden hallinnasta vähemmän systemaattista verrattuna suorien hankintojen hallintaan, mikä lisää tehottomuuden ja kustannusten kasvun riskiä.

Strategisilla valinnoilla yritykset voivat parantaa merkittävästi epäsuorien hankintojen hallintaa (Nair & muut, 2015). Hyvin suunniteltu hallintastrategia ei ainoastaan lisää kustannustehokkuutta, vaan myös varmistaa, että epäsuorat hankinnat tukevat yrityksen strategisia tavoitteita. Ennen hankintastrategiaa yrityksen täytyy pohtia tulevia vaatimuksia ja toimittajakenttää, ja sen jälkeen päätettävä hankintastrategia erikseen jokaiselle kulukategorialle (Weele, 2018, s. 214). Esimerkiksi yrityksen jätehuollolle ja

toimistotarvikkeille tulee pohtia erikseen hankintastrategia. Kulukategorianhallinta mahdollistaa hankintojen priorisoinnin ja resurssien kohdentamisen sinne, missä niistä saadaan suurin hyöty. Sen tavoitteena on siis optimoida kustannuksia.

Ilorannan ja Pajunen-Muhosen (2018, s. 146–150) mukaan kategoriajohtaminen on merkittävä strateginen tapa luokitella ja kehittää yrityksen hankintoja. Ensiksi täytyy jakaa hankinnat omiin kategorioihin ja viimeisessä vaiheessa seurataan kategoriastrategian toteutumista. Alla prosessi kuvailtuna vaihe vaiheelta:

1. Luo kategoria
2. Tutki hankintahistoriaa
3. Tunnista toimittajat
4. Pohdi tarpeita uudelleen
5. Tunnista mahdollisuudet
6. Hahmottele kategoriastrategia
7. Etsi ja arvioi toimittajia
8. Toteuta ja seuraa kategoriastrategiaa

Weelen (2018) mukaan hankintastrategia tukee yrityksen liiketoimintatavoitteita ja luo kilpailuetua. Hän toteaa, että tyypillinen yritysten keino vähentää kustannuksia on toimittajien määrän vähentäminen. Niin ei voi kuitenkaan jatkua loputtomiin, ja Weele toteaa, ettei toimittajien vähentäminen itsessään kuuluisi olla yritysten päämääränä. Sen sijaan on oltava toimiva hankintastrategia.

Weele (2018, s. 215) listaa kolme asiaa, jotka yrityksen olisi päätettävä pohtiessaan hankintastrategiaansa:

1. Yksi vai useampi toimittaja
2. Kansainvälinen vai paikallinen hankinta
3. Kumppanuus- vai kilpailusuhde

Ensimmäinen yrityksen tehtävä päätös liittyy toimittajien määrään eli käyttääkö tietyn tuotekategorian, kuten IT-palvelujen hankintaan yhtä vai useampaa toimittajaa. Jos tiettyssä hankintakategoriassa yritys turvautuu vaan yhteen toimittajaan, niin yritys tulee riippuvaiseksi toimittajasta. Sawikin (2011) mukaan yhden toimittajan strategiassa toiminta voi olla kustannustehokkaampaa, mutta riski toimituskatkoksista kasvaa. Kun toimittajia on puolestaan useita, niin toimitusriski on yleensä pienempi. Strategiat eroavat toisistaan sillä, että yksittäisen toimittajan strategia voi olla edullisempi, mutta se altistaa toimitusketjun korkeille riskeille. Usean toimittajan strategia vähentää riskejä, mutta lisää kustannuksia (Weele, 2018).

Toinen yrityksessä pohdittava asia on, että käytetäänkö kansainvälisiä vai paikallisia toimittajia. Weelen (2018) mukaan vastaus riippuu tuotteen tyypistä ja tarjontamarkkinoiden rakenteesta. Kansainvälisessä hankinnassa korostuvat kustannustehokkuus, laajempi osaaminen ja mittakaavaedut, mutta siihen liittyy logistisia, kulttuurisia ja geopoliittisia riskejä. Paikallinen hankinta puolestaan tarjoaa nopeampia toimituksia, parempaa viestintää ja kestävämpiä ratkaisuja, mutta kustannukset ovat usein suuremmat ja resurssit rajallisemmat. Yrityksen valinta riippuu prioriteeteista, kuten kustannuksista, joustavuudesta ja riskinottokyvystä.

Kolmantena vaiheena on kilpailu- vai kumppanuussuhteen valinta. Haluaako yritys ostaa tuotteen toimittajalta, jonka kanssa kumppanuussuhdetta suositellaan avoimen kirjan laskelmien perusteella, vai pitääkö toimittaja pitää etäisyyden päässä ja suhdetta hallitaan säännöllisellä kilpailulla? Weelen (2018) mukaan kumppanuussuhde tarjoaa pitkäaikaisen yhteistyön, joka tukee innovaatioita, tehokkuutta ja toimitusvarmuutta, mutta voi johtaa riippuvuuteen toimittajasta, mikä heikentää neuvotteluvoimaa. Kilpailusuhde puolestaan mahdollistaa kustannussäästöt, joustavuuden ja laajemman toimittajavaliokoiden, mutta lyhytjänteisyys ja rajallinen tiedonjako voivat heikentää kehitystä. Kumppanuussuhde sopii strategiaan ja kriittisiin hankintoihin, joissa vakaus on tärkeää, kun

taas kilpailusuhde toimii paremmin kustannustehokkuuden ja joustavuuden korostamisessa.

2.2 Epäsuorien hankintojen rooli taloudellisessa suorituskyvyssä

Yrityksen taloudellisen suorituskyvyn kannalta hankintojen hallinta on kriittinen osa liiketoiminnan menestystä (Georgino & muut, 2021). Vaikka epäsuorat hankinnat eivät liity suoraan yrityksen ydintuotantoon, niiden vaikutus yrityksen kustannusrakenteeseen, operatiiviseen tehokkuuteen ja strategiseen kilpailukykyyn on merkittävä. Hausmannin (2023) mukaan epäsuorien hankintojen osuus yritysten liikevaihdosta on keskimäärin 20–40 prosenttia. Täten epäsuorien kulujen optimointi on valtava mahdollisuus parantaa yhtiön tulosta. Epäsuorien hankintojen hallinta ei ole vain kustannusten vähentämistä; se on myös keskeinen tekijä liiketoiminnan optimoinnissa ja pitkän aikavälin taloudellisen kestävyuden varmistamisessa (Georgino & muut, 2021).

Ilorannan ja Pajunen-Muhosen (2018, s. 64) mukaan epäsuorien hankintojen tehokas hallinta voi johtaa merkittäviin kustannussäästöihin, mikä vaikuttaa suoraan yrityksen kannattavuuteen. Heidän mukaansa epäsuorat hankinnat ovat usein laajalle hajautettua monen työntekijän tekemää ostotoimintaa ilman ammattilaisen panostusta, minkä vuoksi selkeällä kehittämisellä voidaan saavuttaa jopa 10 % säästöjä epäsuorien hankintojen arvosta.

Bonfim ja muut (2023) painottavat tutkimuksessaan, että taloudellisesti heikossa asemassa olevien toimittajien valinta voi johtaa toimituskatkoksiin ja laadun heikkenemiseen, mikä vaikuttaa suoraan yrityksen suorituskykyyn. Tämän vuoksi on tärkeää arvioida toimittajien taloudellista vakautta ja varmistaa, että ne pystyvät täyttämään sopimusvelvoitteet luotettavasti, minimoiden näin liiketoiminnan riskejä. Epäsuorien hankintojen tehokas hallinta ei siis rajoitu vain kustannusten optimointiin, vaan se on myös olennainen osa riskien hallintaa.

Epäsuorien hankintojen osuutta voidaan mitata useilla eri talouden mittareilla, kuten osuudella liikevaihdosta tai kokonaiskuluista (Paulraj & muut, 2017). Liikevaihto on keskeinen talouden mittari, joten sen vertailu epäsuoriin hankintoihin antaa käsityksen siitä, kuinka paljon yritys hankkii ei-tuotannollisia toimintoja suhteessa sen liiketoiminnan koon. Esimerkiksi jos yrityksen liikevaihto on 100 miljoonaa euroa ja epäsuorat hankinnat 15 miljoonaa euroa, epäsuorien hankintojen osuus liikevaihdosta on 15 %. Tyypillisesti yritysten epäsuorien hankintojen osuus kokonaiskuluista on noin 40 % (Hausmann, 2023). Jos epäsuorien hankintojen osuus on liian suuri suhteessa kokonaiskustannuksiin, se voi viitata siihen, että yrityksellä on mahdollisesti tehostettavaa toiminnassaan ja hankintastrategioissaan. Toisaalta liian pieni osuus voi tarkoittaa, että tukitoimintoihin ei panosteta riittävästi, mikä voi heikentää organisaation kykyä toimia tehokkaasti. Täten kaikki mahdolliset säästöt epäsuorissa hankinnoissa voi estää kustannussäästöjen tarpeen muilla liiketoiminnan alueilla (Hausmann, 2023).

McKinseyn ja Supple Management -instituution luoma tutkimus osoittaa, että yrityksen menestymisen ja hankintaosaamisen välillä on selkeä yhteys (Reinecke & muut, 2007). Tutkimuksessa tutkittiin 200 suurta yritystä ja niiden hankintaosaamisen vaikutusta kannattavuuteen. Tutkimustulosten mukaan menestyneet yritykset pitivät hankintojen kehittämistä tärkeänä tekijänä yrityksen tulevaisuuden ja strategisen aseman kannalta. Tarkastelujakson aikana heikon hankintaosaamisen omaavat yritykset säästivät hankinnoissaan keskimäärin prosenttia vuodessa, kun taas vahvat yritykset noin kolme prosenttia.

Epäsuorien hankintojen hallinta on keskeinen osa yrityksen strategiaa, mikä voi tuoda kilpailuetua markkinoilla. Hyvin hallitut epäsuorat hankinnat voivat parantaa organisaation reagoitokykyä ja joustavuutta. Tällöin epäsuorat hankinnat eivät ole vain kustannusten hallintaa, vaan ne tukevat liiketoiminnan pitkän aikavälin tavoitteita ja kilpailukykyä (Paulraj ja muut, 2017).

Voidaan todeta, että yrityksen hankintaosaamisen vaikutuksella on suora yhteys menestymiseen ja tuloksentuottamiskykyyn. Tehokkaalla epäsuoran hankinnan johtamisella

voidaan saada kustannussäästöjä ja vahvempaa strategista asemaa markkinoilla. On tärkeää, että yritys tiedostaa epäsuorien hankintojensa nykytilan ja kehittää jatkuvasti hankintatoimintaansa selkeillä hankintojen hallintastrategioilla.

3 Data-analytiikka

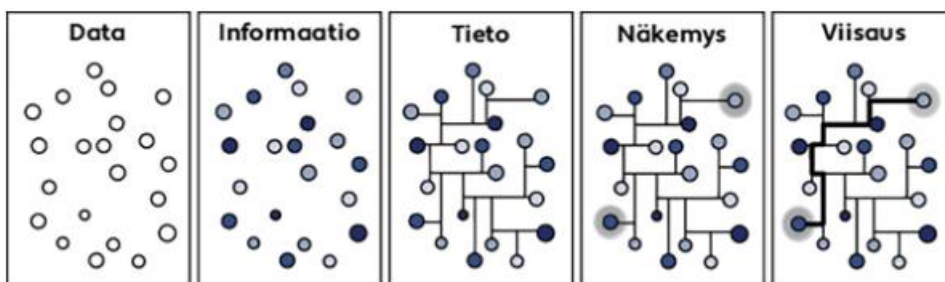
Saatavilla olevan datan määrä kasvaa ja sen hankkiminen on entistä joustavampaa sekä tehokkaampaa. Digitalisaation merkitys yritysten liiketoimintojen prosesseissa kasvaa, minkä myötä organisaatioiden on muutettava toimintatapojaan. Digitalisaation kehitys on ollut mullistavaa viimeisten vuosien aikana verrattuna aikaan 1900-luvulta 2000-luvulle. Vielä 1900-luvulla kaikki liiketoimintaa edistävän tiedon saaminen oli kovan työn takana. Oli mentävä sidosryhmien luokse keskustelemaan asioista ja kaikki tieto joko kirjoitettiin paperille tai pidettiin muistissa. Nykypäivänä liiketoimintaa tehdään toisin. Lähes kaikkien suuryritysten laskentatoimen työntekijöiden tehtävien toiminnot ovat sähköistyneet. Tietokoneet ovat datan säilytysohjelmien sekä monipuolisten järjestelmien myötä valloittaneet hyllyillä aikanaan sijainneet mapit papereineen.

Organisaatioiden työntekijöiden tietotekninen osaaminen korostuu vuosi vuodelta. Työtehtäviä koskeva teoreettinen osaaminen on tärkeää, mutta työpaikan eri järjestelmien käytännön hallinta on myös olennaista. Ilman IT-taitoja työskentely on lähes mahdotonta. Sen havaitsivat myös Picatoste ja muut (2017) tutkimuksessaan, jossa kohderyhmänä olivat 15–24-vuotiaat nuoret. Tutkimuksessa tutkittiin IT-taitojen vaikutusta nuorten työllistymiseen. Tutkimus osoittaa IT-taidoilla olevan suuri merkitys nuorten työllisyyden selittäjänä. Tulevaisuuden laskentatoimen alan ammattilaisten on osattava käyttää tietokoneita mallikkaasti ja ennen kaikkea oltava muutoskykyisiä.

Tässä pääluvussa käsitellään dataa, ja ennen kaikkea sen eri hyödyntämiskeinoja, joita yleisellä tasolla kutsutaan data-analytiikaksi. Aluksi käsitellään dataa itsessään sekä data-analytiikan eri tasoja. Empiriaosassa toteutettavan skenaarioanalyysin ollessa tulevaisuudentutkimusta, ennakoivan analytiikan roolia painotetaan eniten. Pääluvun lopulla käsitellään data-analytiikan merkitystä kulujen hallinnassa.

3.1 Datan määritelmä

Datalle ei ole yhtä oikeaa ja tyhjentävää määritelmää. Salon (2013) mukaan data-sanan kohdatessa ihmisellä herää kaksi ajatusta: dataa on paljon ja sille pitäisi tehdä jotain, jotta siitä saataisiin luotua helposti ymmärrettävää tietoa. Soraya (2018) puolestaan määrittelee datan olevan digitaalisesti esitettyä faktaa, havaintoja sekä raakaa tietoa. Hän painottaa datan itsessään olevan merkityksetöntä jatkojalostamattomana. Kaikki saatavilla oleva data on siis hyödytöntä, jos sitä ei osata analysoida ja hyödyntää. Datasta saadaan louhittua informaatiota, joka muuntuu tietämykseksi, joka puolestaan muuntuu ajan saatossa viisaudeksi, kuten kuviosta kaksi nähdään.



Kuvio 2. Tiedon jalostuminen (Listenmaa, 2023, s. 36).

Listenmaan (2023) kuviossa kaksi edellä mainitun ketjun arvo kasvaa loppua kohden. Hierarkian alimmalla tasolla on data, joka on käsittelemätöntä tietoa ja jolla ei ole kontekstia. Seuraavana on informaation taso, jossa data on käsitelty mielekkääseen ja hyödylliseen muotoon. Kun datasta on saatu informaatiota, niin sitä voidaan muuntaa tiedoksi. Näkemystä saadaan oivalluksina informaatiosta sen analysoinnin ja arvioinnin avulla. Näkemysten avulla voidaan luoda ratkaisuja, tehdä päätöksiä sekä ratkaista ongelmia. Korkeimmalla tasolla on viisaus. Siinä näkemysten kautta tiedon saajat viisastuvat ja tietoa käytetään sekä hyödyllisesti että käytännöllisesti. Viisaudella sovelletaan tietoa epävarmoihin tai haastaviin tilanteisiin ja kokemukseen perustuen tehdään järkeviä arvioita.

Teknologisen aikakauden myötä monet älylaitteet ovat yhdistyneet internetiin ja niiden määrä vain kasvaa. Tätä tilannetta kuvaillaan esineiden internetiksi eli IoT:ksi (Internet of Things) (Cirani & muut, 2018, s. 1). Laitteista saatavan datan määrän siirtyminen verkkoon on kasvanut räjähdysmäisesti viimeisten vuosien aikana. Davenport (2014, s. 11) painottaa, että kyse ei ole pelkästään tietokoneista ja puhelimista vaan nykyään myös esimerkiksi televisiot, termostaatit ja turvallisuusjärjestelmät tuottavat dataa ja ovat yhdistyneet verkkoon. Niistä muodostuneilla tiedoilla voidaan optimoida tarjontaa sekä hallita palvelun käyttöä tulevaisuudessa. Witkowski (2017) toteaa, että termi IoT pitäisi korvata käsitteellä kaiken internet (Internet of Everything). Hänen mukaansa verkkoon kytkeytyneiden laitteiden data syntyy usein esineistä, mutta myös prosesseista, ihmisistä, eläimistä tai maapallon ilmiöistä: kaikista asioista, joita voidaan pitää muuttujina.

Witkowski (2017) määrittää IoT:lle kolme ominaisuutta: konteksti, ”kaikkiällä läsnä oleva” ja optimointi. Kontekstilla viitataan kehittyneeseen väliin, esimerkiksi TV:n vuorovaikutusta sen olemassa olevan ympäristön kanssa ja sen reagoitua mahdollisiin muutoksiin. Kontekstin avulla esineet voivat antaa tietoja, kuten laitteen sijainnin. Kaikkiällä läsnä olevalla tarkoitetaan sitä, että esineet kommunikoivat myös keskenään eivätkä ne luo ainoastaan yhteyksiä ihmisten hyödyntämien verkostojen välillä. Optimoinnin tarkoituksena on havainnollistaa jokaisen esineen toiminnallisuus.

Kirjallisuudessa on esitetty useita jakamistyyppisiä datan rakenteen mukaan. Tunnetuin lienee jako kolmeen osaan: strukturoituun, semistrukturoituun ja strukturoimattomaan dataan. Salo (2013, s. 25) määrittelee strukturoidun datan olevan hyvin määritellyssä muodossa. Sen rakenne on selkeä ja sitä voidaan vaivatta jatkojalostaa informaatioksi sellaisenaan. Esimerkiksi tietojärjestelmien data on strukturoitua. Semistrukturoidulla datalla tarkoitetaan strukturoidun ja strukturoimattoman datan välimuotoa, jolla on jonkinlainen rakenne, mutta jota ei voi muokata yhtä vaivattomasti kuin strukturoitua dataa. Leshcheva & Begler (2022, s. 229) määrittelevät kolmen yleisimmän semistrukturoidun datalähdetyypin olevan taulukkolaskennan (mm. Excel), XML-dokumenttien (mm. datan siirtotiedostot) ja relaatiotietokantojen (tietokannat, joissa on taulukoita, rivejä ja

sarakkeita). Issonin ja Hwangin (2018, s. 34) mukaan strukturoimatonta dataa ovat esimerkiksi kuvat ja videot. Strukturoimattomalla datalla ei ole ennalta määritettyä rakennetta eikä niitä täten voida järjestää ja analysoida perinteisillä työkaluilla.

Strukturoitu ja strukturoimaton data voidaan myös jaotella sisäiseen ja ulkoiseen dataan (Marr, 2015, s. 62–63). Strukturoitu data on usein organisaation sisältä saatavaa dataa, kuten tiedot myynneistä tai varaston sisällöstä. Organisaation ulkopuolelta saatava data on usein strukturoimatonta, jota työntekijät joutuvat jatkojalostamaan ymmärrettävään muotoon. Säätiötiedot sekä organisaation kilpailijoiden sosiaalisen median julkaisut ovat esimerkkejä ulkoisesta datasta.

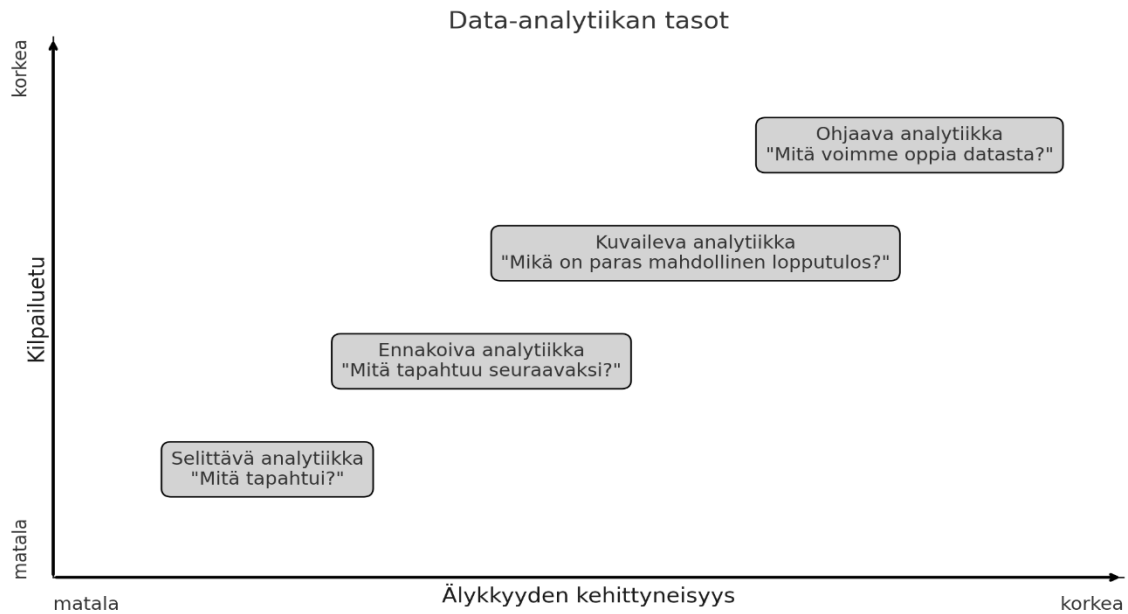
Kolmesta mainitusta datan muodosta eniten on olemassa strukturoimatonta dataa. Salo (2013, s. 25) näkee sen kasvavan määrän olevan yrityksille ongelmallinen, sillä yritykset joutuvat pohtimaan mitä dataa ne tallentavat sekä analysoivat ja mitä eivät. Kaikkea ei kyetä analysoimaan ja sellaisen datan tallentaminen, johon ei koskaan paneuduta vain kuormittaa järjestelmiä. Isson ja Hwang (2018, s. 34) toteavat olemassa olevan datan kasvaneen 800 prosenttia vuodesta 2012 vuoteen 2017 ja yli 80 % kyseisestä määrästä on strukturoimatonta dataa. Olemassa olevasta datasta vain 0,5 prosenttia on analysoitu, mikä myös viittaa strukturoimattoman datan eksponentiaaliseen osuuteen digitalisoituneessa ympäristössä.

Shollo ja Galliers (2016, s. 361) tutkivat datan laatua organisaatioiden päätöksenteossa. He pitävät datan laatua ongelmallisena ja toteavat sen vaikuttavan päätöksenteossa datan luotettavuuteen. Tutkimuksessa tosin selviää, että datan luotettavuus korostuu, kun tehdään yksittäisiä päätöksiä. Shollo ja Galliers (2016, s. 361) määrittävät datan huonon laadun olevan datan hankintaprosessin kaatumisvaihe. He pitävät datan hankkimista vaikeana ja turhauttavana etenkin, jos sitä ei ole onnistuttu tekemään kustannustehokkaasti ja datan laatu on sen lisäksi huonoa.

3.2 Data-analytiikan tasot

Listenmaa (2023) toteaa datan arvottomaksi, jos sitä ei osata analysoida oikein eikä toimia analysoinnista syntyneiden oivallusten mukaisesti. Datan hyödyntämisen tarkoituksena on tuottaa oikeaa tietoa oikeille ihmisille oikeaan aikaan. Se on yksi tärkeimpiä johdon laskentatoimen tehtäviä, jotta informaatiota saadaan koko organisaation tietoon eikä vain johdolle, kuten usein saatetaan ajatella. Nykypäivänä pikaisiin muutoksiin kykenevät organisaatiot luovat itselleen kilpailuetua. Hovi ja muut (2009, s. 76) toteavat liiketoimintaan liittyvien päätösten tapahtuvan entistä nopeammin, sillä muuttuvassa maailmassa aikaa päätösten tekoon on entistä vähemmän.

Data-analytiikka on nykyään kuvaava termi datan hyödyntämiselle, jonka alakäsitteiksi luetaan vielä nykyaikaisemmat analytiikan käsitteet. Appelbaum ja muut (2017) esittävät artikkelissaan kolme analytiikan tasoa, jotka ovat selittävä analytiikka, ennakoiva analytiikka ja kuvaileva analytiikka. Davenport ja muut (2017, s. 26) esittävät näiden lisäksi vielä ohjaavan analytiikan. Näitä neljää analytiikan tasoa käsitellään seuraavissa alaluvuissa. Alla olevassa kuviossa kolme on havainnollistettu data-analytiikan tasojä ja niiden merkitystä liiketoiminnassa.



Kuvio 3. Data-analytiikan tasot (tekoälyllä mukailien Davenport & muut, 2017, s. 27).

Kuviosta kolme voidaan havaita organisaatiolla olevan sitä enemmän kilpailuetua, mitä kehittyneempää analytiikan muotoa se hyödyntää. Se johtuu pitkälti siitä, että mitä kehittyneempi analytiikan muoto on kyseessä, sitä vähemmän sitä käytetään yrityksissä. Useat yhtiöt hyödyntävät selittävää analytiikkaa raportoidessaan menneisyyden tapahtumista, kun taas ohjaavan analytiikan hyödyntäminen on vähäisempää, kun tekoälyn hyödyntäminen on vasta varhaisessa vaiheessa.

3.2.1 Selittävä analytiikka

Vuorisen ja Huikkolan (2023) mukaan selittävää analytiikkaa hyödynnetään, kun tuodaan ilmi menneen ajan informaatiota. Sen tavoitteena on ilmaista historian tapahtumat mahdollisimman selkeästi, jotta voidaan ymmärtää mitä on tapahtunut ja miksi. Selittävä analytiikka on data-analytiikan muodoista kaikista yleisin, sillä selittävällä analytiikalla pystytään melko yksinkertaisin keinoin saamaan ymmärrettävä kuvaus menneistä tapahtumista esimerkiksi dashboardin eli koontinäytön muodossa (Appelbaum & muut, 2017).

Selittävä analytiikka perustuu usein visualisointeihin, yhteenvetoihin ja raportteihin. Niillä luodaan pohja päätöksenteolle tarjoamalla tietoa menneistä tapahtumista. Esimerkiksi raportti edellisen kuukauden myyntiluvuista on tyypillinen selittävän analytiikan tuotos. Yrityksissä ei pitäisi kuitenkaan luoda ainoastaan selittäviä raportteja vastataksseen aiemmin tapahtuviin kysymyksiin, vaan niiden tulisi tehdä myös ennustavia analyysjä esimerkiksi tulevien riskien ja epävarmuuksien seurauksista (Appelbaum & muut, 2017).

3.2.2 Ennakoiva analytiikka

Ennakoivaa analytiikkaa pidetään analytiikan muotona, jonka avulla yksinkertaisesti pyritään ennustamaan tulevaisuuden tapahtumien todennäköisyyksiä historiallisen datan avulla. Sen hyödyntämisellä saadaan vastaus kysymykseen: Mitä tulee tapahtumaan? Ennakoivalla analytiikalla yritykset kykenevät tekemään tehokkaampia päätöksiä sekä suunnittelemaan toimintaansa paremmin. Ennakoivalla analytiikalla on vahva side skenaarioanalyysien kanssa, sillä ennakoivan analytiikan tulevaisuuden ennustamismalleissa on samoja piirteitä kuin skenaariomenetelmissä. Digitalisaation myötä dataa tallennetaan ja varastoidaan runsaasti, minkä vuoksi monet tahot ovat alkaneet käyttämään ennakoivaa analytiikkaa liiketoiminnassaan. (Winters, 2017, s. 9–10; Soraya, 2018, s. 104)

Ennakoiva analytiikka hyödyntää dataa, tilastollisia algoritmeja, matemaattisia malleja sekä koneoppimista ennustamaan liiketoiminnan tulevaisuuden trendien kuten myös taloudellisen suorituskyvyn todennäköisyyttä (Vuorinen & Huikkola, 2023). Datan määrän kasvaessa sekä tekoälyohjelmistojen ja muiden analyttisten työkalujen kehittyessä yritykset voivat hyödyntää ennakoivaa analytiikkaa toiminnassaan. Nykyään esimerkiksi päätösten seurausten ennakointi on mahdollista ennakoivan analytiikan avulla.

Gupta ja muut (2020, s. 582) painottavat matemaattisen mallinnuksen tärkeyttä ennakoivassa analytiikassa. Runsaslukuisen datan myötä prosessointi on haastavaa, mutta jos

siinä onnistutaan, niin yritys parantaa kilpailukykyään. Datan runsauden ja monimutkaisuuden myötä käsittelyyn tarvitaan kehittyneitä datajärjestelmiä. Sorayan (2018, s. 135) mukaan mallintamisessa usein ongelmana ei ole datan määrä vaan sen monipuolisuus. Oikein käytettynä organisaatio saa ennakoivasta analytiikasta itselleen hyvän työkalun tulevaisuuden suunnitteluun.

Tutkimuksen luvussa 6.3 laaditaan laskentamalli, joka ennustaa annetuilla tiedoilla case-yrityksen epäsuoria hankintoja. Ennakoivaa analytiikkaa hyödyntämällä laskentamallissa on mahdollista luoda sekä historiadatan että tulevaisuuden trendien todennäköisyyksien parametreilla epäsuorien hankintojen mahdollisia kehityksiä eri skenaarioissa. Täten case-yritys saa ennakoivasta mallinnuksesta pitkän aikavälin suunnitelmia tukevan menetelmän.

3.2.3 Kuvaileva analytiikka

Datan määrä maailmassa kasvaa eksponentiaalisesti ja on vaikeaa ymmärtää, mikä saatavilla olevasta datasta on hyödyllistä ja mikä ei. Tätä määritelmää kuvaillaan käsitteellä big data. Sen käsittelyä puolestaan big data -analytiikaksi, jonka tavoitteena on tuottaa vaikeasti ymmärrettävästä datasta selkeää, jotta sitä voidaan hyödyntää päätöksenteossa (Soraya, 2018, s. 44–45). Yleisesti liiketoiminnan data-analytiikka perustuu joko sellittävään tapaan, jossa raportoidaan historian tapahtumia tai ennakoivaan, jossa historiallisen datan avulla pyritään ennustamaan tulevaisuutta. Big data -analytiikka määritellään edellä mainittujen yhdistelmäkeinoksi, jossa käytetään reaaliaikaista ulkoista dataa, jonka perusteella voidaan toimia halutun tuloksen saavuttamiseksi. Big data -analytiikka voidaan kutsua kuvailevaksi analytiikaksi.

Kuvailevaan analytiikkaan kuuluu vahvasti mallien hyödyntäminen, jotta suuri määrä eri datamuotoja saadaan prosessoitua. Sen myötä data saadaan ymmärrettävämpään muotoon johtopäätösten tekoa varten. Kuvailevan analytiikan soveltaminen liiketoiminnassa vaatii tietokoneohjelmien hallintaa, mutta ennen kaikkea ymmärrystä siitä, millaisia

tekniisiä työkaluja käytetään eri tilanteissa, jotta paras mahdollinen hyöty saadaan irti datan analysoinnista (Soraya, 2018, s. 57–58).

Appelbaumin ja muiden (2017) mukaan ennakoiva ja kuvaileva analytiikka ovat hyvin samankaltaisia. Niiden keskeisin ero ei ole niihin vaadituissa datatyypeissä vaan analyysin luonteessa. Kuvaileva analytiikka pyrkii vastaamaan kysymykseen: mikä on paras mahdollinen lopputulos? Se on siis optimointilähtöistä, kun taas ennakoiva analytiikka perustuu trendipohjaisiin ennusteisiin.

Appelbaum ja muut (2017) nostavat esille kuvailevan analytiikan vahvuutena sen kyvyn hyödyntää sekä määrällistä että laadullista dataa. Se tekee siitä erityisen arvokkaan nopeasti muuttuvassa liiketoiminnassa. Kuvailevan analytiikan käyttöönotto vaatii kuitenkin vahvaa IT-osaamista sekä laadukkaita järjestelmiä, mikä saattaa olla haastavaa pienille ja keskisuurille yrityksille.

3.2.4 Ohjaava analytiikka

Edellä mainitut kolme analytiikan tasoa ovat olleet jo monen vuoden ajan ajankohtaisia yritysten toiminnassa. Ohjaavan analytiikan nähdään olevan uusin analytiikan alue, jossa mallintamisen kehittämiseen hyödynnetään tekoälyä (Davenport & muut, 2017, s. 26). Tekoälyn avulla pyritään saamaan sellaisia havaintoja, joita ihmiset eivät saa nopeasti tai jopa ollenkaan. Ohjaava analytiikka vastaa kysymykseen: Mitä voimme oppia datasta? Sillä voidaan parhaassa tapauksessa automatisoida päätöksentekoa ja vähentää inhimillisiä virheitä, kuten analyysin vääränlaista tulkintaa.

Bulusu ja Abellera (2021) kutsuvat tekoälyn tuloa data-analytiikan saralle kolmantena sukupolvena, jossa tekoäly mahdollistaa lukuisia analytiikkaratkaisuja päätöksentekoon. Siinä hyödynnetään koneoppimista, tekoälyä, syväoppimista ja kognitiivista laskentaa sekä sitä, kuinka nämä tavat voivat automatisoida data-analytiikkaa ja sen myötä päätöksentekoa.

Ohjaavan analytiikan suurimpina hyötyinä on kyky minimoida ihmisten tekemiä inhimillisiä virheitä sekä jatkuva oppiminen syötetystä datasta (Bulusu & Abellera, 2021). Tekoälyn kyky analysoida samanaikaisesti eri datamuotoja on myös merkittävä etu. Tekoälyllä voidaan analysoida samanaikaisesti strukturoitua ja strukturoimatonta dataa nopeasti ja datan laadun säilyttäen, mikä säästää merkittävästi aikaa ja työntekijän panostusta. Bulusu ja Abellera (2021) kuitenkin huomauttavat, että aiemmin mainittuja kolmea data-analytiikan tasoa tarvitaan edelleen yrityksen toiminnassa. Ohjaavan analytiikan tarkoituksena on hyödyntää aiemmin luotua raportointia kohti tekoälyratkaisuihin perustuvia raportteja, mikä johtaa nopeampaan, älykkäämpään ja automatisoidumpaan tapaan hyödyntää dataa.

Tutkimuksen laskentamallin rakentamisessa hyödynnetään ohjaavan analytiikan piirteitä. Laskentamallin koodi luodaan tekoälyä hyödyntäen, ja koodia muokataan tekoälyn avulla kehotteita antamalla, kunnes päästään haluttuun lopputulokseen.

3.3 Data-analytiikan rooli hankintojen kustannussäästöissä

Digitaalisten teknologioiden nopea kasvu mahdollistaa pääsyn valtavaan määrään dataa, jota voidaan analysoida hankintojen optimoimiseksi. Päätöksiä on mahdollista tehdä sekä historiallisen että reaaliaikaisen datan perusteella. Integroimalla data-analytiikka osaksi hankintojen kehittämistä yritykset voivat kustannussäästömahdollisuuksien tunnistamisen lisäksi luoda myös ennakoivia malleja mahdollisista tulevista hankinnoista sekä myös hallita kustannuksia paremmin. Esimerkiksi toimittajien kanssa luotujen sopimusten analysointi on huomattavasti helpompaa toiminnanohjausjärjestelmän kuin sopimuspaperien kautta. Tässä alaluvussa tutkitaan aiempien tutkimusten tuloksia data-analytiikan hyödyntämisestä kustannussäästöissä.

Rocchion (2016) tutkimuksessa tarkasteltiin, kuinka data-analytiikan avulla voidaan vähentää sairaalan kuluja. Tutkimuksen kohteena oli yhdysvaltalainen terveydenhuolto-

organisaatio Missouriissa. Ongelmana nähtiin polven nivelleikkausten korkeat kustannuserot, minkä seurauksena ryhdyttiin luomaan koontinäyttöä, joka sisälsi reaaliaikaista dataa. Dataa oli lukuisista eri lähteistä ja kun ne saatiin järjestettyä samalle koontinäytölle, niin johtoryhmä sai mahdollisuuden tutkia parannuskohteita reaaliaikaisella datalla sen sijaan, että käytettäisiin historiallista dataa ja sitä täytyisi etsiä monista eri lähteistä.

Rocchion (2016) tutkimuksessa mainittu koontinäyttö otettiin käyttöön vuonna 2014, ja se tarjosi implanttien käytöstä tietoa niin johtoryhmälle, kirurgeille kuin ostotiimillekin. Tilikauden 2014 aikana kustannussäästöjä saavutettiin 1,2 miljoonaa dollaria. Vuonna 2014 saavutettu onnistuminen kustannusten vähentämisessä johti koontinäytön kehittämiseen. Tilikauden 2015 aikana koontinäytön avulla säästöjä saavutettiin 10,7 miljoonaa dollaria, mikä oli noin 15 prosenttia kokonaissäästöistä. Rocchio (2016) huomauttaa, että tärkeää oli saada kustannussäästöjä ilman, että potilaan hoidon laatu kärsi. Siinä he onnistuivat.

Aljohanin (2023) tutkimuksessa tuotiin ilmi case-tapauksia, joissa ennakoivaa analytiikkaa ja koneoppimista hyödynnettiin eri aloilla. Case-tutkimuksissa näytettiin, miten tätä konseptia on sovellettu toimitusketjujen hallinnan parantamiseksi. Case-tapauksien toimialat olivat autoteollisuus, vähittäiskauppa, lääketeollisuus ja teknologia-ala.

Autoteollisuuden tapauksessa yritys hyödynsi ennakoivaa analytiikkaa toimittajien suorituskyvyn arviointiin sekä mahdollisten ongelmien ennustamiseen. Mallin avulla kustannussäästöjä saatiin 750 000 dollaria, mikä osoitti optimointitekniikan taloudelliset edut. Vähittäiskaupan alalla toimivassa yrityksessä asiakkaiden käyttäytyminen ja markkinadynamiikka muuttuvat nopeasti. Sen vuoksi he hyödynsivät ennakoivaa analytiikkaa optimoidakseen varastonhallinnan sekä parantaakseen kysyntäennusteiden tarkkuutta. Analytiikan avulla yhtiö onnistui vähentämään varastonhallintakustannuksiaan 200 000 dollaria, mikä lisäsi kannattavuutta. (Aljohani, 2023)

Lääketeollisuudessa toimiva yritys kehitti historiallisen ja reaaliaikaisen datan avulla ennakoivia malleja, jotka pystyivät havaitsemaan toimittajariskejä ennen kuin ne muuttuivat vakaviksi ongelmiksi. Mallit hiottiin tunnistamaan trendejä, jotka viittasivat toimittajien epärehellisiin toimintatapoihin, kuten lakisääteisten vaatimusten noudattamatta jättämiseen. Mallien hyödyntäminen johti viranomaismaksujen alenemiseen 700 000 dollarista 80 000 dollariin, mikä paransi yhtiön taloustilannetta. Teknologia-alan yritys käytti ennakoivaa analytiikkaa vahvistaakseen toimitusketjuaan geopoliittisia riskejä vastaan, kun he havaitsivat globaalin toimitusverkostonsa mahdollisen haavoittuvuuden. Mallin käyttöönoton myötä toimitusketjun häiriöt ja taloudelliset kustannukset pienenivät merkittävästi 1,2 miljoonasta dollarista 150 000 dollariin. (Aljohani, 2023)

Mandl ja Minner (2023) käsittelivät tutkimuksessaan datalähtöistä lähestymistapaa optimoimaan hyödykehankintoja hintojen epävarmuuden vallitessa. Tutkimuksessa hyödynnettiin kuvailevan analytiikan keinoja, joiden tarkoituksena oli optimoida ostopoliittikoja siten, että päätökset tehdään tyypillisten muuttujien, kuten taloudellisten indikaattoreiden perusteella. Tutkimustulokset osoittivat, että datalähtöinen lähestymistapa voi tuoda merkittäviä säästöjä, sillä kymmenen vuoden takaiseen tilanteeseen sovellettu malli saavutti noin 9,1 miljoonan euron vuosittaisen kustannussäästön verrattuna yrityksen sisäiseen vertailumenetelmään. Saatu säästö olisi ollut 4,33 prosenttia kokonaiskustannuksista.

Deng ja muut (2023) tutkivat Alibaban keinoja hyödyntää analytiikkaa kustannusten vähentämiseksi. Alibaba on yksi maailman suurimmista vähittäiskauppiaista ja verkkokaupan yrityksistä. Artikkelissa tutkittiin Alibaban kehittämiä järjestelmiä, joiden avulla se on onnistunut parantamaan kysynnän ennustamista, varastonhallintaa, hinnoittelua sekä tuotesuosituksia. Kysynnän ennustamiseen yritys kehitti syväoppimiseen perustuvan mallin, jonka myötä kysynnän ennustetarkkuus parani eri liiketoiminnoissa 2–10 prosenttia. Varastonhallintaan kehitettiin simulaatio-optimointi -malli, joka huomioi erilaiset varastomallit, kuten First-In-First-Out (FIFO) ja Last-In-First-Out (LIFO). Mallin avulla pystyttiin vähentämään varastomääriä ja samalla parantamaan asiakaspalvelua.

Hintojen optimointiin Alibaba kehitti koneoppimismallin, jonka tarkoituksena oli analysoida tuotteen hintojen ja kysynnän välistä suhdetta. Mallilla pyrittiin tunnistamaan optimaalinen yhteys hinnalle ja kysynnälle. Mallin myötä tehdyt testit osoittivat myynnin kasvaneen seitsemän prosenttia, kun hinnoittelu tehtiin luodulla mallintamisella. Tuotesuosituksissa yritys loi mallin, joka yhdisti reaaliaikaiset alennukset ja tuotesuosituksien, että ne näkyivät priorisoidusti sellaisille asiakkaille, jotka ovat kuluttaneet kyseistä tuotetta aiemmin. Malli vähensi hävikkiä, mutta nosti myös myyntiä, sillä malli ohjasi kysyntää tehokkaasti potentiaalisille kuluttajille. (Deng ja muut, 2023)

Alibaban kehittämät analytiikkaratkaisut ovat parantaneet asiakaspalvelun tasoa ja tuottaneet merkittäviä taloudellisia tuloksia varastokustannusten ja hävikin vähentämisellä sekä kasvaneilla myyntimäärillä ja -voitoilla. Kaiken kaikkiaan Deng ja muut (2023) arvioivat yhtiön saaneen 42 miljoonan dollarin vuotuiset kustannussäästöt luotujen mallien avulla.

Bhaskaranin (2025) tutkimuksessa kehitettiin Zoom Video Communications yritykselle tekoälymalli nimeltään EnterpriseAI. Yrityksellä on käytössään lukuisia eri järjestelmiä, ja malli luotiin karsimaan yrityksen järjestelmien aiheuttamia kustannuksia sekä tehostamaan liiketoimintaa. Mallissa hyödynnetään suuria kielimalleja, jotta valtavien datamäärien analysointi onnistuu. Sen myötä tekoälymalli voi havaita säästömahdollisuuksia sekä automatisoida yrityksen järjestelmien hallintaa.

Bhaskaranin (2025) tutkimuksen tekoälymallissa keskityttiin vähentämään työntekijöiden manuaalista työtä, minimoimaan virheitä ja parantamaan resurssien allokointia. Manuaalisten työtehtävien automatisointi vähentää virheistä johtuvia uudestaan tehtäviä töitä sekä henkilöstön työtunteja. Malli myös tunnisti minne yhtiön varoja ja henkilöstöä tulisi allokoida työvaiheiden tehostamiseksi. Ennakoivalla analytiikalla malli huomioi riskitekijöitä, minkä myötä yllättävistä ongelmista johtuvat kustannukset jäävät pieniksi.

Yritys testasi malliaan pilottihankkeessaan kansainväliselle valmistusyritykselle, jossa keskityttiin toimitusketjun optimointiin sekä taloudelliseen ennustamiseen. Ennen EnterpriseAI:n käyttöönottoa kokonaiskustannukset olivat 245 000 dollaria. Testijakson aikana kustannukset vähenivät 51 prosenttia 120 000 dollariin. Manuaalisen työn kustannukset vähenivät 58,3 prosenttia ja virheistä johtuvien korjausten kustannukset 66,7 prosenttia. Toimitusketjun optimointia onnistuttiin vähentämään 51,1 prosenttia. Kaiken kaikkiaan yritys onnistui luomaan tekoälymallilla työkalun, jolla kustannuksia onnistuttiin vähentämään merkittävästi.

Edellä mainitut tutkimukset osoittavat, että analytiikkatyökaluja käyttämällä yritykset voivat tunnistaa hankintojen säästömahdollisuuksia. Monipuolisen datan hyödyntäminen analytiikkaratkaisuisissa, vahva IT-osaaminen sekä tehokkaat analytiikkatyökalut ovat keskeisiä tekijöitä, joilla voidaan havaita kustannussäästöjä. Tutkimusten mukaan edistyneiden analytiikkatyökalujen käyttöönotto on olennaista. Siten esimerkiksi toimitusketjun ja toimittajien hallinta on tehokkaampaa.

4 Skenaarioanalyysi

Jatkuvasti muuttuvassa liiketoimintaympäristössä päätöksiä on tehtävä entistä nopeammin. Epävarmuuden vallitessa on syytä pohtia tulevaisuuden näkymiä päätöksenteon yhteydessä. Sargut ja McGrath (2011) toteavat yritysten toimintaympäristön muuttuneen lyhyessä ajassa sekavasta monimutkaiseksi. Johtajien työnkuva on muuttunut haastavammaksi, sillä heidän on vaikea ennustaa tulevaisuuden tapahtumia eri osa-alueiden vaikuttaessa entistä enemmän toisiinsa. Sargut ja McGrath (2011) nostavat esille, että useimmat johtajat eivät hahmota omia kognitiivisia rajojaan. Kukaan johtaja ei kykene hallitsemaan kaikkien liiketoiminnan osa-alueiden näkökantoja. Monimutkaisessa liiketoimintaympäristössä työntekijöiden on luotava yhteyksiä hiljaisen tiedon välille, jotta ymmärrettäisiin paremmin muiden osa-alueiden toimintoja (Meyerowitz & muut, 2018, s. 605).

Sargutin ja McGrathin (2011) mukaan tulevaisuutta ennustettaessa voidaan hyödyntää kolmea datatyyppiä: historiallista, nykyistä ja ennakoivaa. Historiallisen datan hyödyntäminen viittaa siihen, että sen käsittelijät aliarvioivat tulevaisuuden. He ajattelevat tulevaisuudessa kaiken tapahtuvan niin kuin ennenkin. Jos dataa pidetään olennaisena nykyhetkessä, niin sillä nähdään mahdollisuuksia tulevaisuudessa mutta sen hyödyntämistä ei osata soveltaa. Ennakoiva data sisältää tiedot siitä, mihin asiat voivat johtaa tulevaisuudessa ja kuinka erilaisiin tilanteisiin voitaisiin reagoida.

Organisaatioiden ennustamistyökalut saattavat osoittautua hyödyllisiksi strategisessa päätöksenteossa, kun pyritään pysymään mukana arvaamattomassa liiketoimintaympäristössä (Meyerowitz & muut, 2018, s. 603). Hojland ja Rohrbeck (2018, s. 735) toteavat yritysten ennakkoinnin onnistumiseksi organisaatioiden sisällyttävän kolme käytäntöä heidän päätöksentekoonsa: havaitsemista, etsimistä ja kokeilua. Havaitsemisella viitataan yrityksen kykyyn tunnistaa suurin osa markkinoilla vallitsevista muutostekijöistä ja täten saada etumatkaa kilpailijoihin. Peter ja Jarratt (2015, s. 51) toteavat havaitsemisprosessin jälkeen syntyneen listan sisältävän heikot ja vahvat muutossignaalit, kriittiset tapahtumat ja strategiset yllätykset. He painottavat havaitsemisen olevan tärkeää, jotta

organisaatiot voivat sekä ennakoida että valmistautua mahdollisiin häiriöihin. Etsimisellä tarkoitetaan havaitsemisessa tehtyjen löytöjen muuttamista oivalluksiksi (Hojland ja Rohrbeck, 2018, s. 735). Etsimisprosessin tarkoituksena on selvittää, mitä vaikutuksia havaitsemisvaiheen löydöillä on organisaation toimintaan. Täten voidaan tunnistaa ja priorisoida mahdollisia uusia asiakkaita ja markkina-alueita. Viimeisessä kokeiluvaiheessa tutkitaan, mitä eri toimia organisaation pitäisi tehdä (Hojland ja Rohrbeck, 2018, s. 735). Kokeilu antaa valmiudet oppimiselle sekä sopeutumiselle uusille markkinoille ja liiketoimintamahdollisuuksille.

Hammoud ja Nash (2014) tutkivat yritysten keinoja ennustaa tulevaisuutta. Organisaatioiden tulevaisuusajattelu on yleistynyt ja strategista ennakointia käytetään yhä enemmän tulevaisuuksien ennustamisessa. Kyky ennustaa on muuttunut tärkeäksi, sillä siten yritykset pysyvät kilpailukykyisinä ja kykenevät kehittämään uusia liiketoimintamahdollisuuksia. Strateginen ennakointi sisältää käytettävissä olevat keinot, prosessit sekä työkalut, joita johtajat voivat hyödyntää päätöksenteossaan. Hammoud ja Nash (2014) mainitsevat artikkelissaan useita ennustamiskeinoja, jotka auttavat johtajia ymmärtämään tuntematonta tulevaisuutta. Trendianalyysi ja tilastolliset mallit ovat esimerkkejä ennustamiskeinojen hyödyntämisestä, mutta tässä tutkimuksessa keskitytään vain yhteen ennustamismenetelmään: skenaarioanalyysiin. Case-yritykselle luodaan neljä eri skenaariota, joiden kuvaukset esitetään luvussa 6.4.

4.1 Skenaarion määritelmä

Sanalle skenaario on esitetty kirjallisuudessa lukuisia määritelmiä. Varum ja Melo (2010, s. 356) määrittävät skenaarioiden perustuvan ymmärrykseen, että maailma on arvaamaton, tosin tietyt asiat ovat ennalta määrättyjä. Mikään skenaario ei heidän mukaansa anna tarkkaa tulevaisuudenkuvaa. Skenaarioiden tehtävänä on luoda johtajille ymmärrys tulevaisuudesta, jonka myötä he voivat harkita ja tunnistaa mahdollisia epävarmuuskijöitä. IPCC:n (Intergovernmental Panel on Climate Change) mukaan skenaario on johdonmukainen ja uskottava kokonaisuus tulevaisuuden tilasta (Nowack ja muut, 2011, s.

1605). Skenaario ei ole ennuste vaan kuvaus tulevaisuudesta ja skenaarion prosessista, kuinka siihen voidaan päätyä. IPCC määrittää, että usean skenaarion joukko hyväksytään usein silloin, kun ne kuvastavat mahdollisimman kattavasti skenaarioiden epävarmuuden vaihteluväliä. Jotkin skenaariot voivat siis olla hyvinkin todenmukaisia ja toiset taas monen epävarman muuttujan varassa.

Godet (2000, s. 11) kuvailee skenaarion olevan tulevaisuuden tilasta muodostuva kokonaisuus siihen johtavista tapahtumista, jotka mahdollistavat siirtymisen lähtöasetelmasta tulevaisuuden tilaan. Hän luokittelee skenaariot kahteen kategoriaan: tutkivaan ja ennakoivaan. Tutkivissa skenaarioissa työskentely aloitetaan historian ja nykyajan hetkistä ja niiden perusteella muotoillaan todennäköiset tulevaisuuskuvat. Ennakoivat skenaariot ovat tulevaisuudennäkymiä, joihin halutaan päätyä tai vastaavasti, joihin pelätään päätyvän. Börjeson ja muut (2006, s. 725–726) lisäävät tutkivan ja ennakoivan skenaarion kategoriaan myös ennustavan näkökulman. Sen tavoitteena on ennustaa mitä tulevaisuudessa tulee tapahtumaan. Börjeson ja muut (2006, s. 725) tiivistävät näiden kolmen kategorian vastaavan erilaisiin kysymyksiin. Ennustavat skenaariot vastaavat kysymykseen ”mitä tulee tapahtumaan”, ennakoivat kysymykseen ”mitä voi tapahtua” ja tutkivat skenaariot kysymykseen ”kuinka tiettyyn tavoitteeseen päästään”.

Mannermaa (1999, s. 58) toteaa, että ennakoivat skenaariot muodostetaan etenemällä retrospektiivisesti tulevaisuudesta nykyhetkeen. Hän pitää sekä ennakoivan että tutkivan skenaarion tapoja tärkeinä. Tutkivia skenaarioita on mahdollista muodostaa tilanteesta ja ongelman luonteesta riippumatta. Ennakoivia skenaarioita puolestaan on haastava muodostaa yhteiskunnallisissa skenaarioissa, sillä silloin yksimieliseen tavoitettiin päästään harvoin. Yrityksen skenaariotyöskentelyssä taas ennakoivan skenaarion hyödyntäminen on välttämätöntä, sillä yrityksen on mahdotonta suunnitella ja luoda strategiaa, jos haluttua tavoitetilaa ei ole määritelty (Mannermaa, 1999, s. 59). Tässä tutkimuksessa mallinnetut skenaariot ovat luonteeltaan tutkivia skenaarioita, sillä niissä tarkastellaan menneisyyden sekä nykyhetken trendiä ja pyritään niiden perusteella luomaan mahdollisia tulevaisuuksia.

Schoemaker (1995) painottaa skenaarioiden tarkoituksena olevan epävarmuuden rajoittaminen tulevaisuudessa. Organisaatiot harvoin pitävät yllätyksistä, varsinkaan negatiivisista, minkä vuoksi tulevaisuuden korostaminen on toivottavaa, jotta kyettäisiin välttämään epävarmuustekijöitä. Mannermaa (1999, s. 57) määrittelee skenaarion seuraavasti: *”Skenaariomenetelmällä luodaan loogisesti etenevä tapahtumasarja, jonka tarkoituksena on näyttää, miten mahdollinen, joko todennäköinen, tavoiteltava tai uhkaava tulevaisuudentila kehittyy askel askeleelta nykytilasta”*. Hänen mukaansa skenaariolla on oltava kolme ominaisuutta: sen on kuvattava lähtötilannetta, tulevaisuudentilaa sekä prosessikuvausta, joka liittyy kaksi aiemmin mainittua yhteen. Kaikkien luotujen skenaarioiden on oltava saavutettavissa ja ne voivat olla epätodennäköisiä, uhkaavia tai tavoiteltavia (Mannermaa, 1999, s. 57–58).

Jo toisen maailmansodan aikaan sodassa toimineet johtajat kehittivät skenaarioiden sarjoja mahdollisista vihollisten tekemistä ratkaisuista (Meyerowitz & muut, 2018, s. 602). Herman Kahn toimi aikanaan Yhdysvaltojen armeijassa strategiasuunnittelijana ja häntä pidetään skenaarioiden kehittämisen uranuurtajana (Mahmoud & muut, 2009, s. 799). Hän itse määritteli 1950-luvulla skenaarion olevan hypoteettisista tapahtumasarjoista muodostuva kuvaus tulevaisuudesta, jonka tarkoituksena on vastata kahteen kysymykseen: Miten jotkut hypoteettiset tilanteet syntyvät skenaarioprosessin aikana ja mitä vaihtoehtoja toimijoilla on jokaisessa vaiheessa prosessin ohjaamiseksi, estämiseksi tai helpottamiseksi (Aligica, 2004, s. 75). Kahn painotti Aligican (2004, s. 76) mukaan sitä, että skenaarioihin liittyy sekä ihmisen kognitiivisuuden että mielikuvituksen näkökulma ja skenaariot pyrkivät kuvaamaan yksityiskohtaisesti sekä mahdollisimman ymmärrettävästi hypoteettisia peräkkäisiä tapahtumia.

Skenaariomenetelmän synty sekä suosioon nousu tapahtui vuoden 1973 öljykriisin aikaan, jolloin Shell-yhtiö alkoi ensimmäisinä hyödyntämään skenaarioanalyysia tulevaisuuden suunnittelussa (Wack, 1985, s. 72). Shell loi skenaarion, jossa Lähi-Idän maat päättäisivät pysäyttää öljyn viennin länsimaihin. Skenaario toteutui, minkä vuoksi öljyn

hinta kohosi nopeasti ja syntyi öljykriisi. Pierre Wack toimi yhtiön skenaariotyöskentelyn johtohahmona ja hänen tiiminsä onnistui ennustamaan öljykriisin. Yhdessä tiiminsä kanssa Wack kehitti tulevaisuuden skenaarioita ja niiden mahdollisia vaikutuksia Shelliin. Yhtiön johto ymmärsi tulevaisuuden ennustamisen paremmin skenaariotyön edetessä ja heidän onnistuneen valmistautumisensa ansiosta Shell selvisi öljykriisistä paremmin kuin kilpailijansa.

4.2 Skenaarioanalyysi suunnittelumenetelmänä

Bradfieldin ja muiden (2005, s. 810) mukaan skenaarioanalyysien pitkästä olemassaolosta huolimatta niitä ei ole toistaiseksi sovellettu organisaatioissa strategisen suunnittelun tukena vielä 2000-luvulla. Skenaarioanalyysi on prosessikeskittynyt lähestymistapastrategiaan, joka usein eroaa tavallisista lähestymistavoista ja jota luonnehditaan rationalistiseksi tavaksi etsiä optimaalinen strategia (Varum & Melo, 2010, s. 356). Skenaarioanalyysiä suositellaan entistä enemmän päätöksenteon parantamisen tueksi, joka on hyödyllinen apuväline jopa pienissä yrityksissä. Oliver ja Parrett (2018, s. 340) toteavat skenaarioanalyysin olevan strateginen ennustamisväline, joka on jo kauan nähty yhtenä mahdollisista puolustustoimista ennalta arvaamatonta tulevaisuutta vastaan.

Mikään skenaario ei pysty luomaan tarkkaa kuvausta tulevaisuudesta. Schoemaker (1995, s. 38–39) toteaa skenaarioanalyysin roolin olevan johtajien auttaminen todennäköisten epävarmuustekijöiden tunnistamisessa, pohtimisessa sekä harkitsemisessa. Hänen mukaansa johtajien tunnistessa tulevaisuuden epävarmuustekijät ja suunnat, he kykenevät rakentamaan skenaarioita päätöksenteon tueksi tekemättä tyyppisiä tulevaisuuden päätöksenteon suunnittelun virheitä, kuten liiallisen itseluottamuksen käyttämistä. Sen vuoksi skenaarioanalyysin suunnittelussa hyödynnetäänkin erilaisissa asemissa olevien työntekijöiden, kuten asiantuntijoiden, strategiiden ja johtajien osallistumista, joista jokainen antaa omat näkemyksensä vaihtoehtoisista tulevaisuudentiloista. Strategisten skenaarioiden syntymisen jälkeen organisaation johtoryhmä voi levittää niitä liiketoiminnan eri osa-alueille edistääkseen johtamisajattelua. Syntyneitä skenaarioita voi käyttää myös

ehdotusten arviointia varten (Schoemaker, 1995, s. 27). Vecchiato ja Roveda (2010, s. 1538) uskovat strategisen ennakkoinnin lisäävän johtajien ymmärrystä monimutkaisesta liiketoimintaympäristöstä. Sen myötä heidän strategiset ennakointitaitonsa kehittyvät ja täten johtajat pystyvät valmistautumaan paremmin tulevaisuuden uhkiin ja mahdollisuuksiin.

Schoemaker (1995, s. 27) listaa kahdeksan tilannetta, joiden tapahduttua skenaarioanalyysiä olisi kannattavaa hyödyntää organisaatiossa:

1. Epävarmuutta on enemmän ilmassa suhteessa johtajien kykyyn ennustaa tai sopeutua muutoksiin.
2. Liian monta negatiivista yllätystä on tapahtunut historian saatossa.
3. Organisaatio ei havaitse tai luo uusia mahdollisuuksia.
4. Strategisen ajattelun laatu on heikkoa.
5. Toimiala on kokenut merkittävän muutoksen tai muutos on tapahtumassa.
6. Organisaatio haluaa yhteisen kielen organisaation sisälle, kuitenkin monimuotoisuutta poistamatta.
7. Mieli-pide-erot tulevaisuuden ennustamisesta ovat vahvoja.
8. Kilpailijat hyödyntävät skenaarioanalyysiä.

Skenaarioanalyysin tehokas hyödyntäminen onnistuu tietyin vaatimuksin. Werner (1990, s. 55) toteaa skenaarioprosessin olevan enemmän kuin teknistä osaamista: se myös luo sitoutumista sisäinen politiikka ja kulttuuri huomioiden. Skenaariot on suunniteltava siten, että huomio kiinnittyy vain ydinkysymyksiin, ja sen on tarjottava keino, jolla voidaan valita organisaatiolle kulttuurillisesti sekä poliittisesti sopivat riski- ja tuottovalinnat. Skenaarioanalyysin olisi myös tarjottava väline, jonka avulla voidaan valita järkevät vaihtoehdot strategioista, ja se olisi suunniteltava käyttämään tietoa, joka sisältyy organisaation yhteiseen tietämykseen.

Harris (2014, s. 38–39) tuo esille väärin muuttujiin keskittymisen, todellisten uhkien huomioimatta jättämisen sekä riittämättömän arvioinnin tyypillisiksi skenaarioissa esiintyviksi virheiksi. Chermack ja muut (2010, s. 143–144) toteavat skenaarioanalyysin edellyttävän luovuutta ja vankkaa ymmärrystä liiketoimintaympäristöstä. Heidän mukaansa skenaarioiden muodostaminen on mutkattomampaa, kun on kykyä pohtia ympäristön mahdollisuuksia, kilpailijoiden tekoja sekä kansainvälisiä muuttujia, jotka ohjaavat sosiaalisia, poliittisia ja taloudellisia järjestelmiä. Vuorinen ja Huikkola (2023) toteavat PEST-analyysin olevan keino toimintaympäristön ymmärtämiselle. Siinä tutkitaan organisaation poliittista, taloudellista, sosiaalista ja teknologista asemaa. PEST-analyysistä saa hyvän yleiskuvan toimintaympäristöstä, mutta analyysin ollessa yleistävä se ei anna organisaatiolle paljon apua strategiseen ennakkointiin. Cairns ja muut (2010, s. 975) toteavat, että ympäristötekijöitä analysoitaessa jokaista tekijää olisi kuvattava mahdollisimman yksityiskohtaisesti aihealueen sekä sijainnin osalta. Mitä laadukkaammin tekijät on kuvailtu, sitä helpompaa skenaarioiden luominen on. Tässä tutkimuksessa case-yrityksen toimintaympäristöä tutkitaan PESTEL-analyysiä hyödyntäen, jossa mainitun PEST-analyysin lisäksi tarkasteluun lisätään myös ekologiset ja lainsäädännölliset seikat.

Skenaarioprosessin on onnistuakseen oltava tehokas. Meyerowitz ja muut (2018, s. 603) painottavat prosessivaiheiden tärkeyttä. Tehottomuus jossakin skenaarioprosessin vaiheessa johtaa skenaarioanalyysin heikkenemiseen. Sadler-Smith (2008, s. 499) korostaa intuitiolla olevan merkitystä arvaamatonta tulevaisuutta analysoitaessa. Intuitiivisella ajattelulla luodaan nopeita ja tunneperäisiä päätöksiä, jotka eivät perustu tietoon tai perusteltuun päättelyyn. Intuition hyödyntäminen on silti välttämätöntä, koska mikään määrä historialliseen tietoon perustuvia analyysyjä ei anna päätöksentekijöille riittävää vastausta monimutkaiseen liiketoimintaympäristöön. Millettin (2003, s. 18) vankka näkemys on, että hyvä skenaarioprosessi alkaa johtajan lausunnolla siitä, miksi skenaarioita tarvitaan ja mitä tavoitteita niillä pyritään saavuttamaan.

Chermack ja Nimon (2013, s. 816) nostavat onnistuneen skenaarioanalyysin vaatimukseksi ajan ja energian käyttämisen tärkeyden. Nykyajan teknologisilla menetelmillä

skenaarioiden suunnittelu on hankalaa, sillä monet skenaarioiden luomisvaiheen aspektit menetetään. Esimerkiksi videokokousten sekä elävän tilanteen interaktiivisten keskustelujen kehonkielen ja keskeytysten vivahteita on haastavaa dokumentoida. Cairns ja muut (2016) nostavat artikkelissaan esille sidosryhmien käyttäytymisen sekä skenaariosuunnittelutiimin yhteistyön sujuvuuden skenaarioanalyysin vaatimuksiksi. Kaiken kaikkiaan onnistuneen skenaarioanalyysin luominen vaatii tarkkaa tietämystä vallitsevasta ympäristöstä. Haluttu lopputulos saavutetaan, kun lähtökohdat ennen prosessin aloittamista ovat kontrollissa.

4.2.1 Skenaarioanalyysin vaiheet

Tieteellisessä kirjallisuudessa on monta vaihtoehtoa skenaariotyöskentelyn prosessin eri vaiheille, mutta Balarezon ja Nielsenin (2017, s. 6–9) toteama viisivaiheinen prosessi on melko tyypillinen. Siihen kuuluu toimintaympäristön arvioiminen, tulevaisuuskuvien rakentaminen, skenaarioiden valmistuminen, saadun tiedon levittäminen organisaatioon ja skenaarioiden aktiivinen seuranta sekä niiden jatkuva hallinta.

Skenaarioanalyysin muodostuminen alkaa toimintaympäristön tutkimisella. Se on tärkeä osa ennen skenaarioiden rakentamista, missä tunnistetaan muun muassa toimialan avaintekijöitä sekä yrityksen sidosryhmien asemaa (Cairns, 2010, s. 975). Laadukkaan ympäristön skannausprosessin jälkeen saaduilla informaatioilla on mutkattomampaa muodostaa skenaarioita. On kuitenkin myös vääristymiä, joihin ympäristön skannausvaihe voi olla alttiina. Kuvaas (2002, s. 978) toteaa ihmisten olevan taipuvaisia itsevarmuuteen. Jälkiviisaus ja vahvistus ovat esimerkkejä, joiden myötävaikuttaessa altistutaan helposti etsimään tietoa, joka vahvistaa alkuperäiset oletukset sen sijaan, että etsittäisiin tietoa, joka on ristiriidassa oletusten kanssa. Beckin ja Plowmanin (2009, s. 914) mukaan ympäristön havainnointi perustuu tunnettuihin tapahtumiin, koska ihmiset keskittyvät tiedonkeruussa asioihin, joita he pitävät omasta mielestään tärkeinä. Ympäristön tutkimisvaihe voi siis tuoda vääristymiä heti skenaarioanalyysiprosessin alkuvaiheessa.

Toisessa vaiheessa rakennetaan skenaariot. Börjeson ja muut (2006, s. 730) määrittävät sen aluksi koostuvan ideoiden ja datan keräämisestä, sitten niiden yhdistämisestä kokonaisuuksiksi ja lopuksi skenaarioiden johdonmukaisuuden tarkastamisesta. Erilaiset tekniikat skenaarioiden rakentamiseen voidaan jakaa tuottamis-, yhdistämis- ja johdonmukaisuustekniikoihin. Tuottamistekniikoissa luodaan näkemyksiä ja tietoa tulevaisuudesta. Työpaikkojen työpajat, kyselyt tai haastattelut ovat esimerkkejä tuottamistekniikoista. Kyseisen tekniikan avulla voidaan luoda muun muassa mallilaskelmia ja lähtötietoja skenaarioiden tueksi (Börjeson & muut, 2006, s. 730). Yhdistämistekniikoissa käytetään usein matemaattista mallinnusta. Mallinnukseen kuuluu monta tekniikkaa, joiden avulla osia yhdistetään kokonaisuuksiksi. Mallinnustekniikat eivät ota huomioon mahdollisia liiketoiminnan suuria muutoksia, minkä vuoksi ne eivät sovellu niin hyvin tulevaisuuskuvien luomiseen. Niiden avulla pystytään kuitenkin osoittamaan nykyisten trendien suunta (Börjeson & muut, 2006, s. 734). Johdonmukaisuustekniikoita käytetään ideoiden luomiseen ja yhdistämiseen, mutta niiden tärkeimpänä etuna nähdään skenaarioiden välisen tai niiden sisäisen johdonmukaisuuden varmistaminen. Alaluvussa 4.2.2 käydään syvällisemmin läpi tunnetuimpia skenaarioiden muodostamistekniikoita.

Kolmas vaihe sisältää skenaarioiden valmistumisen. Skenaariot ovat skenaarioanalyysiprosessin keskeisin osa. Vaikka skenaarioiden muodostamistekniikoita on lukuisia, niin silti niistä on haastavaa saada onnistuneita. Baconin (2012) mukaan skenaariosta muodostuu yleensä mielikuvituksettomia ja ne keskittyvät liikaa ajankohtaisiin asioihin. Usein tulevaisuuden epävarmuudet jätetään analyysin ulkopuolelle. Bacon (2012) tutki 13 erilaista skenaariopohjaista tutkimusta ja havaitsi, että jokaisessa tapauksessa luodut skenaariot muistuttivat liikaa toisiaan ja muodostetut tulevaisuudet olivat tyypillisiä eikä tavallisesta poikkeavia. Mannermaa (1999) toteaa, että skenaarioiden ollessa valmiita olisi suotavaa, että ne olisivat erilaisia. Jokin skenaario voi olla epäjohdonmukainen ja haluttu, toinen taas mahdollinen mutta epätodennäköinen ja jokin voi korostaa keskeisiä haavoituvuuksia. Skenaariot ovat valmistumiseen saakka jokseenkin sosiaalisia prosesseja ja Balarezo ja Nielsen (2016, s. 8) pitävät ihmeellisenä sitä, kuinka vähän on tutkittu kognitiivisten tekijöiden ja psykologian vaikutusta skenaarioiden tehokkuuden kehittämisessä.

Neljännessä vaiheessa skenaarioista saatavaa tietoa tulevaisuudesta aletaan viljelemään organisaation sisällä. Tiedon siirtäminen ei ole yksinkertaista, sillä se vaatii vankkaa yhteistyötä sekä tiedon antajalta että vastaanottajalta. Bresman (2013) sanookin tiimien välisen tiedonsiirron olevan avainasemassa. Työntekijöiden on tehtävä kaikki tarvittava, jotta tieto saadaan muutettua vastaanottajan kannalta merkitykselliseksi. Mannermaa (1999, s. 60) toteaa, että skenaarioiden pohjalta organisaatiossa luodaan visio. Se olisi hyvä olla yhteisesti laadittu, jotta eri näkökulmat otetaan huomioon. Samalla luodaan myös missio eli polku, joka johtaa visioon. Täten kommunikointi tiimien välillä on tärkeässä osassa, jotta jokaisella työntekijällä olisi tieto tavoitteista ja tavoista, joilla ne saavutetaan.

Yleisesti skenaarioanalyysia pidetään jatkuvana prosessina. Viimeisessä vaiheessa skenaarioita jäädään seuraamaan ja niitä uudistetaan tai korjataan muuttuneiden olosuhteiden mukaisesti. Miller ja Waller (2003) toteavat aktiivisen epävarmuustekijöiden seuraamisen johtavan organisaation reagoitakyvyn parantumiseen. Myös jatkuva skenaarioiden päivittäminen ja ulkopuolisen ympäristön muutosten seuraaminen edesauttaa sitä. Luotujen skenaarioiden ja strategian välillä ei ole usein vahvaa sidettä, minkä vuoksi monet skenaarioanalyysit epäonnistuvat. Loppuvaiheessa niihin pitäisi panostaa enemmän ajan kanssa. Päätöksenteon tukivälineenä skenaarioanalyysin on oltava jatkuva prosessi (Heinonen & Lauttamäki, 2012, s. 312). Siten siitä saa oivan työkalun sekä johtoryhmän että koko työyhteisön tueksi.

4.2.2 Työkaluja skenaarioanalyysin muodostamiseen

Vuorisen ja Huikkolan (2023) mukaan skenaarioiden laatimisessa voidaan hyödyntää lukuisia menetelmiä. Skenaarioanalyysin toisessa vaiheessa rakennetaan skenaariot, ja tässä alaluvussa esitetään erilaisia skenaarioiden luontikeinoja. Yleisimpiä ovat TIA-menetelmä (trend impact analysis), CIA-menetelmä (cross impact analysis) sekä delfoimenetelmä.

TIA-menetelmä on määrällinen tutkimus, ja se on yksi käytetyimmistä tulevaisuuden ennakointimenetelmistä. Popin ja Grigorasin (2021, s. 3) mukaan TIA-menetelmä on niin sanottu etsintämenetelmä, jossa tutkitaan, kuinka jotkin tapahtumat voisivat muuttaa valittujen trendien ekstrapolointia. Ekstrapoloinnilla tarkoitetaan trendin tai käyrän arvon määrittämistä mittaustulosten ulkopuolelta (Luo & muut, 2019, s. 2117). TIA-menetelmä kehittyi 1970-luvulla, kun määrällisiä menetelmiä menneen ajan datan analysoinnille oli vähän tarjolla. Sen ajan menetelmät eivät huomioineet mahdollisia tulevaisuuden tapahtumia. Täten kehittyi TIA, jossa tulevaisuuksien trendien tarkastelu sekä niiden käyttäytymisen tarkastelu muutoksessa on mukana.

Agami ja muut (2008, s. 1439) toteavat TIA:n olevan lähestymistapa, joka on sekoitus määrällistä ja laadullista ennakointimenetelmää. He määrittävät TIA:lle kaksi tarpeellista ominaisuutta, joista toinen viittaa määrälliseen tietoon ja toinen laadulliseen. Ensiksi menetelmän kuvaavan käyrän on perustuttava menneelle datalle, joka mittaa käyrän muodon, kun ei oteta huomioon tulevia arvaamattomia tapahtumia. Toiseksi asiantuntijoiden arvioita käytetään tunnistamaan tulevaisuuden tapahtumia. Tämä on laadullinen menetelmä. Jokaisen heidän mielestään poikkeavan tapahtuman osalta he luovat todennäköisyyden ajan funktiona ja sen vaikutusta tulevaisuudessa. Käyrän kurssi muuttuu joko positiiviseen tai negatiiviseen suuntaan, jos tapahtumalla on suuri vaikutus (Agami & muut, 2008, s. 1440).

Bradfield ja muut (2005, s. 801) näkevät TIA-prosessin olevan nelivaiheinen. Aluksi kerätään data kyseessä olevista muuttujista, jonka jälkeen luodaan algoritmi trendien ekstrapolointia varten. Kolmannessa vaiheessa laaditaan lista mahdollisista tulevaisuuden tapahtumista ja lopuksi tunnistetaan mahdollisten tapahtumien vaikutusta trendeihin. Tässä tutkimuksessa hyödynnetään TIA-menetelmää, johon paneudutaan uudestaan empiriaosuuden luvussa 6.2.

CIA-menetelmä on toinen tässä tutkimuksessa esitetty määrällinen tulevaisuuden tutkimismenetelmä. Se on yksi käytetyimmistä menetelmistä skenaarioanalyysissä (Ghasemian & muut, 2020). CIA-menetelmä on systemaattinen menetelmä, jonka tarkoituksena on tuottaa pitkän aikavälin ennusteita (Sapio, 1995, s. 115). Sitä käytetään tyypillisesti silloin, kun tulevaisuus näyttää normaalia epävarmemmalta ja eri tekijöiden yhteyttä ei ymmärretä. Menetelmän keskeisenä ajatuksena on, että johonkin ennustamista vaativaan tapahtumaan voi vaikuttaa myös muut tapahtumat. Sapion (1995, s. 115) mukaan menetelmässä hyödynnetään matemaattisia tekniikoita löytämään skenaario, joka on yhtenäisin arvojen kanssa. Matemaattisten mallien hyödyntäminen skenaarioanalyysissä johtaa vakuuttaviin lopputuloksiin, ja koska ihmismielen käsitys riippuvaisuustekijöistä on rajallinen, niin usein skenaarioiden pelkkä sanallinen kuvaaminen ei riitä, vaan tarvitaan myös numeerisia arvoja (Weimer-Jehle, 2006, s. 335).

Banuls ja Salmeron (2007, s. 753) määrittävät CIA-menetelmän seitsemään vaiheeseen:

1. Tapahtumien määrittely
2. Tapahtuman alkuperäisen todennäköisyyden arviointi
3. Ristikkäisvaikutusten määrittäminen matriisissa
4. Matriisin vaikutusten kalibrointi
5. Herkkyydestin määrittäminen matriisilla
6. Ristikkäisvaikutusten laskeminen herkkyydestiä varten
7. Tulosten arviointi

CIA-menetelmä on oiva keino strategiseen suunnitteluun, sillä sen avulla voidaan analysoida muuttujien vaikutusta toisiinsa (Ghasemian & muut, 2020). Se sopii hyvin käytettäväksi yhdessä delfoimenetelmän kanssa, sillä silloin skenaarioiden suunnittelussa hyödynnetään sekä asiantuntijoiden näkemyksiä että dataa. Matriisin valmistuttua voidaan aloittaa skenaarioiden luominen. Tapahtumien vaikutusten merkitys toisiinsa on varteenotettavin tekijä CIA-menetelmässä. Niiden pohjalta onnistuu tulevaisuuskuvien rakentaminen.

Kolmas yleinen ennakointimenetelmä on delfoimenetelmä. Se on asiantuntija-arviointimenetelmä, ja TIA:sta sekä CIA:sta poiketen laadullinen tutkimusmenetelmä. Se on luotu ryhmän kommunikaatiovälineeksi, jonka tarkoituksena on saada luotettava ja yksimielinen mielipide kyselylomakkeiden avulla, joilla asiantuntijoilta saadaan hallittu mielipidepalaute (Landeta, 2006, s. 468). Delfoimenetelmässä on useita kyselykierroksia, joiden vastausten perusteella luodaan lopputulos. Delfoimenetelmässä viesti välittyy ihmisten välillä siten, että he voivat tarjota arvokasta panosta monimutkaisen ongelman ratkaisemiseksi.

Landeta (2006, s. 468–469) määrittää delfoimenetelmälle neljä ominaisuutta:

1. Sen on oltava toistuva prosessi. Vastaajien on saatava sama kysymys ainakin kahdesti, jotta he voivat toisella kerralla harkita vastaustaan uudelleen muilta vastaajilta saatujen tietojen pohjalta.
2. Menetelmän osallistujien tai ainakin heidän antamien vastausten on pysyttävä nimettöminä. Ainoastaan skenaariotyöskentelyn koordinaattori käsittelee vastauksia. Sen vuoksi vastaajien ajalla ja paikalla ei ole väliä, ja nimettömyydellä pyritään myös välttämään vastaajien kesken syntyvää negatiivista vaikutusta, jota esimerkiksi organisaatiossa olevan vastaajan aseman suhteen voisi syntyä.
3. Vastaajien palaute on oltava hallittua. Vastaajat eivät saa vapaasti vaihtaa näkemyksiään toisten kanssa vaan se tapahtuu koordinaattorin toimesta. Täten epäolennainen tieto saadaan hävitettyä.
4. Vastaajien lopulliset vastaukset on oltava tilastollisia. Lopullinen vastaus koostuu kaikista mielipiteistä. Kysymykset muotoillaan siten, että vastaukset voidaan esittää tilastollisesti.

Delfoimenetelmässä on merkittävää huomata, että sitä käytetään skenaarioiden luomisessa etenkin silloin, kun dataa ja tietoa ei ole tai sen hankkiminen on joko kallista tai vaikeaa (Giesecke & muut, 2015, s. 50). Menetelmässä hyödynnetään sellaisia

kysymyksiä, joihin on mahdollista saada mitattavissa olevia vastauksia. Delfoimenetelmä on osoittautunut tehokkaaksi ja tarkaksi menetelmäksi. Parenten ja muiden (1984) tutkimuksen mukaan jopa 95 prosenttia delfoimenetelmää hyödyntäneen ryhmän ennusteista oli parempia kuin yksittäisten panelistien luomat ennusteet.

Giesecke ja muut (2015, s. 50) määrittelevät delfoimenetelmän vaiheita. Aluksi suunnitteluryhmä tekee skenaarioita ja luo näistä luonnoksista kysymyksiä asiantuntijoille, minkä jälkeen asiantuntijat käyvät luonnokset läpi ja antavat palautteen. Tämän jälkeen suunnitteluryhmä tekee vastauksista yhteenvedon ja päivittää vastausten perusteella skenaarioita. Sitten materiaali jaetaan uudestaan asiantuntijoille toista kierrosta varten, jonka aikana asiantuntijat täydentävät vastauksiaan ja antavat palautetta suunnitteluryhmän muokkaamista skenaarioista. Tämän jälkeen ryhmä tarkentaa skenaarioluonnoksiaan palautteen perusteella ja lähettää ne uudestaan asiantuntijoille. Mannermaan (1999, s. 152) mukaan tätä jatketaan niin kauan, kunnes asiantuntijoiden palautteet eivät enää muutu. Hänen mukaansa usein kaksi kierrosta riittää, sillä sen jälkeen palautteiden sisällön muuttuminen on vähäistä. Kun asiantuntijat ovat antaneet lopullisen palautteensa skenaarioista, niin suunnitteluryhmä toteuttaa skenaarioiden lopullisen luonnoksen (Giesecke & muut, 2015, s. 50).

Skenaarioanalyysien menetelmät perustuvat strategiselle suunnittelulle. Kukaan ei haluaisi tietää mitä tulevaisuudessa tapahtuu tai voisi tapahtua. TIA ja CIA luokitellaan määrällisiin menetelmiin ja delfoimenetelmä laadullisiin, vaikkakin nykyään skenaariomenetelmät sisältävät sekä määrällisiä että laadullisia piirteitä. Esimerkiksi Banuls ja Salmeron (2007, s. 751) toteavat CIA:n olevan mukautuva menetelmä, minkä vuoksi sitä voidaan yhdistää muihin menetelmiin. Delfoimenetelmän myötä skenaariosuunnittelu on mahdollista ilman olemassa olevaa dataa. Menetelmän avulla asiantuntijoiden muodostamista vastauksista on mahdollista tunnistaa keskeiset tulevaisuuden uhat ja mahdollisuudet, jonka jälkeen voidaan koota uskottavia ja vankkoja skenaarioita. TIA-menetelmässä puolestaan hyödynnetään sekä historian dataa että asiantuntijoiden näkemyksiä tulevista tapahtumista.

4.3 Datan rooli tulevaisuudentutkimuksessa

Tulevaisuuden tutkiminen on lähes mahdotonta ilman menneisyyden tai nykyhetken dataa. Jokaisessa skenaarioanalyysin prosessissa on oltava dataa, sillä ilman sitä ei voida rakentaa mahdollisia tulevaisuuksia, jos ei edes tiedosteta menneitä tapahtumia tai ihmisten mielipiteitä. Datan rooli skenaarioanalyysissä tulee esiin skenaarioiden rakennusvaiheessa, jossa dataa kerätään joko määrällisesti historiallista tai tämänhetkistä dataa hyödyntämällä, tai laadullisesti esimerkiksi kyselyillä tai haastatteluilla (Van Notten, 2003, s. 426).

Van Notten (2003, s. 426) toteaa, että skenaarioanalyysin prosessin alkuvaiheessa tehdään päätös siitä, käytetäänkö tutkimusmenetelmässä määrällistä vai laadullista dataa. Laadullisiin menetelmiin kuuluu sellaisen datan käyttö, joista muodostetaan intuition tai näkemysten perusteella skenaarioita. Interaktiivisten ryhmäkeskustelujen tai kyselyjen analysointi ovat esimerkkejä keinoista, joista voidaan muodostaa laadullista dataa. Van der Heijdenin (2000, s. 33–34) mukaan laadullisen datan hyödyntämisen jälkeen skenaarioista muodostuu joustavia ja niitä voidaan vaivattomasti muokata, jos skenaarioprosessin aiemmissa vaiheissa ilmenee kehitettäviä piirteitä. Määrällistä dataa hyödynnetään puolestaan silloin kun skenaarioiden esittämisessä on havaittavissa analyttisiä ominaisuuksia. Silloin skenaarioiden luomisessa hyödynnetään usein tietokoneita, joilla luodaan matemaattisia malleja sekä simulointitekniikoita (Van Notten, 2003, s. 426). Tyypillisesti laadullista dataa hyödynnetään silloin, kun määrällistä dataa on vähän tai sitä ei ole ollenkaan saatavilla (Rotmans & muut, 2000, s. 813).

Rotmansin ja muiden (2000) mukaan sekä laadullisen että määrällisen datan hyödyntäminen skenaarioiden muodostamisessa tekee niistä kestävämpiä ja johdonmukaisempia. Laadullisella datalla voidaan rikastaa määrällisen datan avulla suoritettua skenaariota, jonka myötä sen ymmärrettävyys paranee, kun lukujen lisäksi skenaarioihin liitetään myös laadullista dataa, kuten tekstiosuuksia havainnoista. Päinvastoin taas laadullisilla menetelmillä luodut skenaariot voidaan todentaa uskottavimmiksi liittämällä mukaan määrällistä dataa (Van Notten, 2003, s. 431–432).

Seuraavissa alaluvuissa käsitellään datan merkitystä tulevaisuudentutkimuksessa. Luvussa esitetään aikaisempia aiheeseen liittyviä tutkimuksia ja analysoidaan niitä. Aluksi käsitellään datan käyttämistä skenaarioiden luonnissa, jossa pohditaan muun muassa millaista dataa skenaarioissa käytetään ja kuinka datan keruu tapahtuu. Datan kasvavan määrän ja entistä digitalisoituvan liiketoimintaympäristön myötä tässä luvussa tutkitaan myös big datan ja ennakoivan analytiikan merkitystä skenaarioanalyysissä. Luvun lopussa esitetään vielä, millaisia aiempia skenaarioanalyyskejä on tehty.

4.3.1 Datan käyttö skenaarioiden rakentamisessa

Datan määrän kasvun sekä monipuolistumisen myötä sen käyttömahdollisuudet kasvavat myös tulevaisuuden arvioinnissa. Datankeruuvaiheen tarkoituksena on saada konkreettista faktaa, jotta skenaariot voidaan muodostaa. Siinä dataa kerätään joko osallistavilla (laadullisilla) tai omatoimisilla (määrällisillä) keinoilla (Van Notten, 2003, s. 432). Osallistavissa menetelmissä hyödynnetään ihmisten näkemyksiä ja mielipiteitä, joita antavat esimerkiksi alan asiantuntijat. Aiemmin käsitelty delfoimenetelmä on muun muassa menetelmä, jossa dataa saadaan ihmisiä osallistavilla keinoilla. Omatoimisilla keinoilla viitataan puolestaan tapoihin saada dataa, joihin ei vaadita yksilöiden välistä vuorovaikutusta. Kyseisissä tilanteissa dataa kerätään kaikkialta missä sitä on saatavilla, kuten internetistä, sanomalehdistä, tietokannoista, tilastoista ja työpaikan data-aineistoista (Hoover Green & Cohen, 2021).

Mahmoud ja muut (2009) toteavat mallintamiseen perustuvissa skenaariomenetelmissä skenaarioiden esiintyvän datakokonaisuuksina, jotka kuvaavat keskeisimpien muuttujien ajallisia muutoksia. Mallinnusmuotoiset skenaariomenetelmät koostuvat kolmesta vaiheesta: järjestelmien käsitteellistämisestä, mallinnustavan valinnasta ja kehittämisestä sekä datan keruusta ja sen jatkojalostamisesta. Liun ja muiden (2008) näkemys on, että kun skenaarioihin käytetään mallinnuspohjaista lähestymistapaa, niin täytyy luoda käsitteellinen malli keskeisten tekijöiden tunnistamiseksi. Se mahdollistaa skenaarioiden

määritelmien ja käytettävien mallien selkeän yhteyden. Järjestelmän, jossa mallinnus luodaan, tavoitteena on lisätä ymmärrystä ja helpottaa viestintää sidosryhmien välillä, määrittää skenaarioiden tarkoitus, kuvata tärkeimpiä päätöksiin vaikuttavia tekijöitä ja tarjota väline prosessien ja muuttujien seurannalle. Mallinnustavan on oltava yhdenmukainen käsitteellisen mallin kanssa muun muassa muuttujien suhteen. Kun laskennallinen malli on valmis, siihen voidaan kerätä dataa. Malliin kerätään dataa, se prosessoidaan jokaiselle skenaariolle ja lopuksi mallin tuottamat tulokset käsitellään (Mahmoud & muut, 2009).

Silva ja muut (2021a) loivat skenaariota itseohjautuvien ajoneuvojen vaikutuksesta kaupunkiympäristöön. Käsiteltävinä kohteina oli pysäköintipaikkojen tarve tulevaisuudessa ja tutkimus suoritettiin Unkarin pääkaupungin Budapestin yhdelle kaupunginosalle. Skenaarioiden tavoitteena oli arvioida pysäköintikysynnän tulevia muutoksia ja niiden vaikutusta kaupunkiympäristön muutokseen. Skenaarioiden luontiin käytettiin sekä määrällistä että laadullista dataa. Laadullinen data kerättiin kyselyillä alueen asukailta. Kyselyitä palautettiin 150 kappaletta. Määrällinen data koostui muun muassa aikaisempien tutkimusten sisältämästä datasta sekä internetistä saadusta datasta, joiden pohjalta luotiin laskennallinen malli, jossa hyödynnettiin sekä laadullista että määrällistä dataa.

Silva ja muut (2021a) ottivat tutkimuksessaan huomioon tutkittavan asuinalueen viisi tekijää, jotka he kokivat oleellisina skenaarioiden rakentamiselle. Ne olivat ajoneuvojen lukumäärä, liikkumismuoto, auton omistusmuoto, pysäköintitapa sekä kaupunkiympäristön muuttaminen tärkeysjärjestykseen pysäköintitarpeet huomioiden. Niiden pohjalta aloitettiin skenaarioiden rakentaminen. Tutkijat jakoivat skenaarioissa käytettävät data-lähteet kolmeen osaan: joko nykyistä dataa oli saatavilla tai sitten ei. Kolmas muoto oli tulevaisuuden ennusteista saatava data tulevista muutoksista. Saatavilla olevaa määrällistä dataa kerättiin viranomaisten raporteista sekä konsultointiyhtiöiden selonteista, jotka määrittivät markkinoiden ennako-odotuksia. Jos dataa ei ollut saatavilla, niin sitä kerättiin joko kyselyiden muodossa tai samankaltaisen kaupunginosan tiedoista. Esimerkiksi ajoneuvojen lukumäärä ja liikkumismuoto pystyttiin arvioimaan toisen kaupungin

datalla, kun sillä oli samanlaisia ominaisuuksia kuin tutkittavalla alueella, kuten pinta-ala ja väkiluku. Auton omistusmuodon ja pysäköintitavan arvioiminen suoritettiin kyselyillä alueen asukkailta. Tulevaisuuden ennusteisiin perustuva data kerättiin myös kyselyillä.

Silva ja muut (2021a) toteavat, että skenaarioiden muodostamisessa on kannattavaa hyödyntää sekä määrällistä että laadullista dataa, jos mahdollista. Viiden skenaarion muodostumiseksi hyödynnettiin laskennallista mallia, joka oli luotu Silvan ja muiden (2021b) tutkimuksessa. Malli muodostui viiden vaiheen kautta. Ensimmäisessä vaiheessa laskettiin pysäköintipaikkojen määrä kysynnän mukaan ja toisessa vaiheessa pysäköintialueiden kysyntä. Prosenttiosuus vapaista paikoista yksityisalueilla sekä nouto- ja jättöalueilla laskettiin kolmannessa vaiheessa. Neljännessä vaiheessa mallissa arvioitiin pinta-ala uusia käyttökohteita varten. Lopuksi laskettiin ympäristösäästöjen prosenttiosuus.

Goodspeedin ja muiden (2023) luomassa skenaarioanalyysissä tutkijat tekivät skenaarioita, joilla saataisiin parannettua joukkoliikenteen asemaa Michiganin asuinalueella Yhdysvalloissa. Skenaarioprosessi kesti vuodesta 2019 vuoteen 2022. Tutkimus suoritettiin yhteistyöpainotteista sekä dataperusteista skenaariosuunnittelua hyödyntämällä. Tutkijat loivat sekä tutkivia skenaarioita, joihin hyödynnettiin määrällistä dataa, että kuvailevia skenaarioita, joiden saavuttamiseksi hyödynnettiin laadullista dataa.

Goodspeed ja muut (2023) keräsivät dataa lukuisista lähteistä, mikä edesauttoi skenaarioiden uskottavuutta projektin päättyessä. Skenaarioprosessi sisälsi kolme työpajaa, joista laadullinen data kerättiin. Ensimmäinen työpaja järjestettiin lähitapaamisena, toinen Zoom-sovelluksen välityksellä ja kolmas hybriditapahtumana. Laadullinen data koostui työpajoihin ja haastatteluihin osallistuvien näkemyksistä sekä kyselyiden vastauksista. Vuonna 2015 tehtyä kyselyä matkustamisesta ja liikkumisesta asuinalueen ihmisistä hyödynnettiin, kuten myös matkustustarpeeseen liittyvää kyselyä, joka kohdistettiin heikossa asemassa oleviin asuinalueen ihmisiin, kuten heikkotuloisiin tai iäkkäisiin. Määrällinen data koostui suurimmaksi osaksi alueella liikkuvien ajoneuvojen GPS-datasta sekä

asukkaiden mobiililaitteiden sensoridatasta. Niiden avulla pystyttiin havaitsemaan, millä kaupungin alueilla liikehdintä oli suurta ja millä taas ei.

Goodspeed ja muut (2023) loivat datan keräämisen jälkeen kolme erilaista mallia, joiden myötä määrällisen ja laadullisen datan yhdistäminen onnistui. Ensimmäinen malli luotiin arvioimaan matkustamisen kysyntää alueiden välillä. Siinä hyödynnettiin pelkästään laadullista dataa. Toisen mallin tarkoituksena oli arvioida sitä, kuinka ihmisten matkustustarpeet liittyvät tulevaisuuden liikkumispalveluihin. Kolmas malli oli monipuolinen. Sen avulla laskettiin alueen työpaikkojen määrä sekä asukkaiden lukumäärä. Sen myötä skenaarioiden luontitilaisuudessa osalliset loivat optimaalisia reittejä tulevaisuudessa, joista hyötyisi niin kaupunki kuin sen asukkaatkin.

Schweizer ja muut (2021) hyödynsivät big dataa ja mallinnusta, joiden avulla he loivat tarkkoja ennusteita liikenteen käyttäytymisestä sekä skenaarioita liikenteen kehittymisestä. Tutkimuksen kohteena oli Bolognan kaupunki Italiassa. Skenaarioprosessi sisälsi paljon samoja piirteitä kuin Goodspeedin ja muiden (2023) skenaarioanalyysi. Schweizer ja muut (2021) havaitsivat, että mallit vaativat suuren määrän dataa, minkä vuoksi pienetkin virheet mallinnuksessa voivat johtaa merkittäviin epäkohtiin skenaarioita muodostaessa prosessin loppuvaiheessa. Tutkijat käyttivät malleja skenaarioiden luonnissa. Kyselyistä, GPS-datasta, internetistä sekä satelliittikuvista muodostettiin mallinnuksen lähteet, joiden pohjalta skenaariot rakennettiin. Tutkijat painottivat, että big datan lisääntyminen sekä teknologian kehittyminen mahdollistavat enemmän joustavuutta ja vaihtoehtoja skenaarioiden luomiselle mallien kautta.

Ray ja muut (2017) loivat skenaarioanalyysin Intian vehnän tuottamisesta TIA-menetelmää hyödyntämällä. Prosessissa käytettiin mallia, johon yhdistettiin Intian vehnän dataa historian saatossa sekä asiantuntijoiden näkemyksiä tulevaisuuden tapahtumista. Analyysissä tutkijat loivat kaksi mallia, jotka he yhdistivät, jonka jälkeen skenaariot muodostettiin. Tutkimus osoitti TIA:n olevan oiva keino, kun tulevaisuudessa nähdään tapahtuvan innovaatioita teknologian saralla ja silloin, kun täysin arvaamattomia tapahtumia

huomioidaan. Tutkijoiden mukaan TIA on hyvä sen joustavuuden vuoksi. Sillä voi luoda useita mahdollisia skenaarioita ja sitä voi vaivatta muokata, jos havaitaan, että jokin tapahtuma tulee tapahtumaan jonakin tiettyä aikana.

Edellä mainituissa tutkimuksissa luodut skenaarioanalyysit osoittavat, että skenaarioprosessissa hyödynnettävä data voi olla hyvin monipuolista. Tutkimuksissa hyödynnettiin sekä määrällistä että laadullista dataa, minkä myötä niissä luodut skenaariot mahdollistavat joustavan reagoinnin tulevaisuuden kehityspolkuihin.

4.3.2 Skenaarioita datan hyödyntämisestä tulevaisuudessa

Tulevaisuudessa digitalisaatio kiihtyy, minkä vuoksi organisaatiot siirtyvät entistä enemmän digitaalisiin järjestelmiin. Digilaitteiden kasvun myötä myös datan määrä kasvaa. Culot ja muut (2020) loivat skenaarioanalyysin tulevaisuuden tuotannosta. Skenaarioanalyysi neljännessä teollisesta vallankumouksesta luotiin delfoimenetelmällä, johon osallistui 76 alan asiantuntijaa. Prosessin lopuksi muodostettiin kahdeksan skenaariota, jotka perustuivat neljään muuttuunaan asiantuntijoiden kommentteista. Yksi niistä oli datan rooli. Tutkijat loivat 43 ennustetta neljännessä teollisesta vallankumouksesta. Ennusteet luotiin aikavälille 2019–2030.

Datan roolin nähdään muuttuvan entistä merkittävämmäksi tekijäksi liiketoiminnassa. Seuraavassa listassa mainitaan asiantuntijoiden näkemyksiä datan tulevaisuudesta eri aihealueiden parissa:

1. Digitaaliset toimijat tuottavat dataa, jota tarvitaan arvoketjun toiminnassa.
 - Valmistusyrityksillä data on yksi tuotannontekijöistä.
 - Ulkoista dataa tarvitaan älylaitteiden datavetoisissa palveluissa. Sisäinen data ei riitä.
2. Yrityksen tuottamaa dataa myydään muille toimijoille.
 - Lisää mahdollisuuksia datan kaupankäynnille syntyy, sillä niiden merkitys tulee kasvamaan.

- Dataan liittyviä säännöksiä tullaan kehittämään tukemaan datan kaupallistamista.
- 3. Datahallinnan toiminta koskee vain pientä määrää globaaleja toimijoita.
- Dataa säilytetään organisaation sisällä kilpailuedun pitämiseksi.
- Suuret yritykset tulevat hallitsemaan paremmin datahallinnan tuomia innovaatiopaineita.
- 4. Valmistusyritykset tulevat sisäistämään datahallinnan toiminnot.
- Datahallintaa tarvitaan kilpailemiseen datavetoisessa toimintaympäristössä.
- Älylaitteiden yleistyminen vaatii valmistusyritykseltä vankkaa hallintaa niiden datasta.
- 5. Arvoketjussa datahallintaan liittyvät toimet nähdään tärkeinä.
- Datan kasvava merkitys tukee organisaation katteiden kasvua.
- Datan hallinta tarjoaa yrityksille lisätulonlähteitä.

Bokrantz ja muut (2017) ovat myös luoneet vuoteen 2030 saakka olevia skenaarioita delfoimenetelmää hyödyntämällä. He keräsivät delfoimenetelmän laadullisen datan työpaikoista, haastatteluista sekä kirjallisuudesta. Kerätyt datat vietiin laadulliseen datanhallintajärjestelmään, jossa data jatkojalostettiin. Delfoimenetelmän myötä syntyi 34 ennustetta organisaation eri osa-alueista.

Bokrantz ja muut (2017) havaitsivat, että asiantuntijoiden näkemysten mukaan data-analytiikan kehitys jatkuu. Data-analytiikan kehittymisen myötä yritysten tuottavuus lisääntyy, kun kyetään tunnistamaan liiketoimintaa häiriköiviä piirteitä. Näkemysten mukaan dataa voidaan kerätä ja analysoida automaattisesti, ja datan keräämisen yleisen hintatason nähdään laskevan. Big datan hallinnan merkitys korostuu myös vuoteen 2030 mennessä. Suuren datamäärän haasteena nähdään resurssien ja data-analysoinnin osaamisen mahdollinen puute. Datan laadun säilyttäminen hyvänä ja datahallintajärjestelmien kehittäminen siis nähdään tulevaisuuden ongelmakohtina. Niiden välttäminen edistää data-analytiikan hyödyntämistä päätöksenteon tukena.

5 Case-yrityksen toimiala

Case-yritys harjoittaa liiketoimintaa valtakunnallisessa ajoneuvomarkkinassa. Tässä luvussa esitetään case-yrityksen toimialan piirteitä sekä yleiskatsaus toimialan markkinasta ja tulevaisuuden näkymistä. Luvun lopussa case-yrityksen epäsuorat hankinnat jaotellaan pienempiin osiin. Niiden kehitystä ennakoidaan luvun kuusi empiriaosiossa.

5.1 Yleistä autoalasta ja -markkinasta

"Joku on sanonut, että autoalalla tapahtuu nyt seuraavan 10 vuoden aikana enemmän kuin viimeisen 100 vuoden osalta, ja tämä väite on kyllä helppo allekirjoittaa". (KaaraTV Podcast, 2023)

Yllä oleva sitaatti on Autoalan Keskusliiton (AKL) toimitusjohtajan Tero Lausalan toteamus autoalan murroksesta. Yhden tai kahden suuren innovaation sijaan alalla on käynnissä lukuisia rinnakkaisia kehityskulkuja, jotka yhdessä johtavat poikkeuksellisen nopeaan ja laajaan muutokseen. Autokannan sähköistyminen, kansainväliset ympäristövaatimukset, kuluttajakäyttäytymisen muutokset sekä teknologiset harppaukset ovat esimerkkejä syistä, joiden myötä autoala muuttuu ja tulee muuttumaan tulevina vuosina (Ziegler & Abdelkafi, 2023).

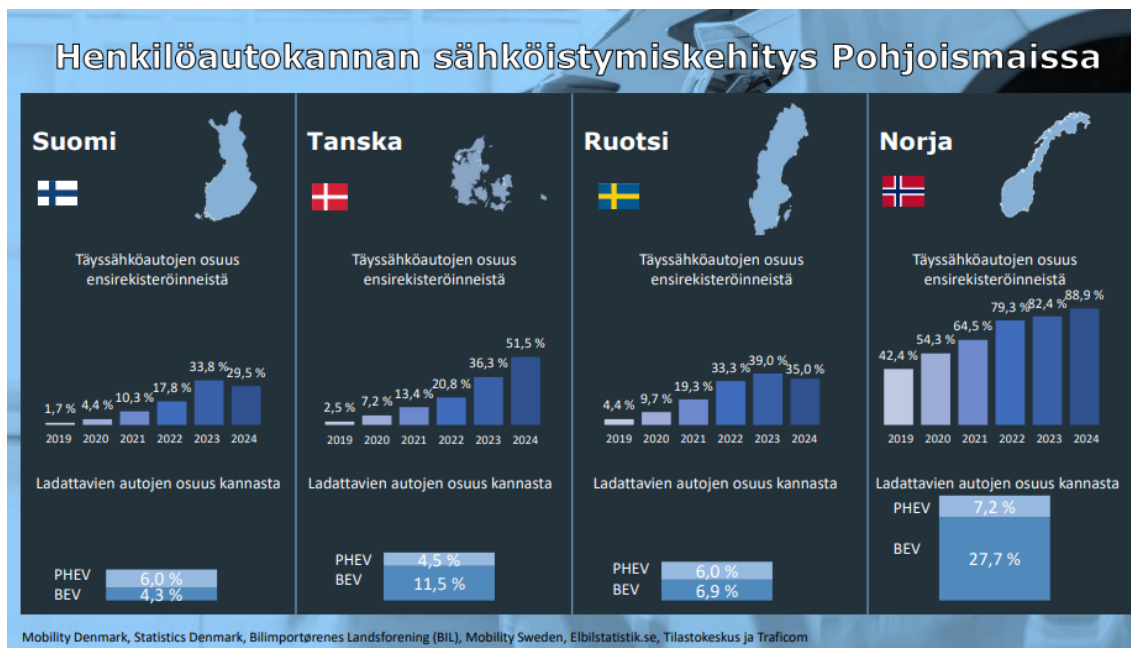
Suomessa autoala muodostuu pääasiassa vähittäiskaupan toimijoista. Suurin osa Suomessa myytävistä autoista on kansainvälisten valmistajien luomia. Suomessa ajoneuvojen keski-ikä on EU:n korkeimpia, sillä yli 40 prosenttia autokannasta on vähintään 15 vuotta vanhoja (Lausala, 2024). Autokannan uusiutuminen olisi tärkeää liikenneturvallisuuden parantamiseksi, sillä uudet autot ovat kehittyneiden turvallisuusteknologioiden ansiosta turvallisempia kuin vanhat autot.

Sähköautojen suosio on kasvanut viime vuosina muun muassa laajentuneen latausinfrastruktuurin sekä vuonna 2021 tehdyn täyssähköisten työsuhteautojen verokannusteen

luonnin vuoksi, jonka myötä täyssähköisen ajoneuvon verotusarvosta voi vähentää 170 euroa kuukaudessa tuloverotuksessa (Autoalan Tiedotuskeskus, 2024). Markkinoille on myös tullut eri koko- ja hintaluokan sähköautomalleja, mikä on madaltanut kuluttajien kynnystä siirtyä sähköautoiluun.

Ympäristötietoisuus on merkittävä ajuri autoalan muutoksessa. Liikenne on suuripäästöinen ja ainoa ala, jossa kasvihuonekaasupäästöt ovat EU:ssa korkeammat kuin vuonna 1990 (Valtioneuvoston tulevaisuusselonteko, 2024). EU on asettanut jäsenmailleen päästövaatimuksia, mikä pakottaa Suomen valtiota tiukentuvaan sääntelyyn. Suomi on sitoutunut puolittamaan liikenteen päästöt vuoteen 2030 mennessä ja olemaan täysin hiilineutraali vuonna 2035 (Valtioneuvoston tulevaisuusselonteko, 2024). Näiden tavoitteiden saavuttamiseksi keskeisintä on siirtyminen uusiutuvan energian hyödyntämiseen ajoneuvoissa. Kyseinen ilmiö tapahtuu viimeistään vuoden 2035 aikana, jolloin Euroopan markkinoilla saa myydä ainoastaan sähköautoja, kun EU kieltää polttomoottorilla varustettujen henkilö- ja pakettiautojen myynnin, jotta tieliikennesektorista tulisi ilmastoneutraali (European Commission, 2023). Edellä mainitut tavoitteet ja vaatimukset tulevat vaikuttamaan Suomen autokannan kehitykseen ja autoalan rakenteeseen.

Viime vuosina autokanta on muuttunut entistä sähköisemmäksi, mutta Suomessa muutos ei ole ollut niin nopeaa kuin muissa Pohjoismaissa, minkä näkee kuvasta yksi. Kuvassa PHEV (Plug-In Hybrid Electric Vehicles) tarkoittaa ladattavaa hybridiä, joka toimii kahdella tai useammalla voimanlähteellä, kuten sähköllä ja polttomoottorilla. BEV (Battery electric vehicle) tarkoittaa täyssähköautoa eli ajoneuvo toimii pelkästään akulla ilman polttomoottoria. Näiden yhteisosuus henkilöautokannasta oli noin 10,3 prosenttia, kun esimerkiksi Norjassa vastaava luku oli 34,9 prosenttia.



Kuva 1. Henkilöautokannan sähköistymiskehitys Pohjoismaissa vuosina 2019–2024 (Autoalan Tiedotuskeskus, 2025).

Vuonna 2024 autoalan markkina oli käytettyjen autojen osalta kasvussa edelliseen vuoteen verrattuna. Käytettyjä henkilöautoja myytiin yhteensä 617 604 kappaletta, mikä on 4,3 prosenttia enemmän kuin vuonna 2023. Uusia henkilöautoja puolestaan ensirekisteröitiin 74 072 kappaletta, mikä on 15,4 prosenttia vähemmän kuin vuonna 2023. Käytettyjen autojen osuus kaupoista oli huomattavan suuri, mikä osoittaa kuluttajien suosivan edullisempia hankintoja taloudellisen epävarmuuden aikana. Korkea korkotaso ja kuluttajien heikentynyt luottamus talouden kehitykseen olivat merkittävät syyt uusien autojen vähentyneen kysynnän taustalla. (Autoalan Tiedotuskeskus, 2025)

5.2 Case-yrityksen epäsuorat hankinnat

Autoliikkeiden edellytys tuloksen saamiseksi on tiivistettynä ajoneuvojen ostaminen halvemmalla kuin niiden myynti. Suurimmat kulut tulevat siis autojen ostoista. Tyypillisesti ajoneuvoihin liittyvät varustelut ja korjaukset kuuluisivat suoriin hankintoihin, mutta

tässä tutkimuksessa ne sisällytetään epäsuoriin hankintoihin. Täten yhtiön epäsuoriin hankintoihin sisältyy kaikki kuluerät paitsi ajoneuvojen ostotilit.

Epäsuorien hankintojen käsitteen ollessa laaja, on case-yrityksen epäsuorat hankinnat jaettu neljään erään:

1. Operatiiviset kulut
2. Vuokrat ja kiinteistökulut
3. Henkilöstökulut
4. Muut kiinteät kulut

Operatiivisiin kuluihin kuuluu muun muassa ajoneuvojen korjauskulut, ajoneuvojen siirroista aiheutuvat kulut sekä ajoneuvojen varaosakulut. Edellä mainittujen kulujen hallinta ja optimointi ovat keskeisessä roolissa, jotta voidaan parantaa kannattavuutta ja vähentää tarpeettomia kustannuksia. Aiemmin mainitun data-analytiikan hyödyntäminen tarjoaa mahdollisuuksia tehostaa operatiivisia prosesseja ja saavuttaa merkittäviä kustannussäästöjä tästä kuluerästä.

Case-yrityksellä on lukuisia toimipisteitä. Toimitilojen käytöstä syntyy vuokratkustannuksia. Niiden lisäksi toimitiloja on huollettava, minkä vuoksi syntyy muun muassa siivous- ja ylläpitokuluja. Nämä ovat yksi neljästä epäsuorien hankintojen eristä.

Suurin osa case-yrityksen henkilöstökuluista oli työntekijöiden palkkoja, mutta niiden lisäksi henkilöstökuluihin kuuluu työttömyysvakuutusmaksut, työnantajan eläkemaksut, sosiaaliturvamaksut sekä muut henkilösivukulut. Neljäs ja viimeinen erä sisältää kaikki muut yhtiön kiinteät kulut. Tässä kuluerässä merkittävimmät kulut tulevat markkinoinnista sekä IT:stä. Erään kuuluu muun muassa digi- ja printtimarkkinointi, ohjelmistojen lisenssimaksut, matkaliput, ATK-palvelut sekä ATK-tarvikkeet, kuten puhelimet ja kannettavat tietokoneet.

6 Tutkimusmenetelmät ja aineisto

Case-tutkimustyyppit voidaan jakaa interventionistisiin ja ei-interventionistisiin tutkimuksiin (Lukka & Wouters, 2022). Lukan ja Woutersin (2022) mukaan interventionistisessä tutkimuksessa tutkija osallistuu aktiivisesti case-yrityksen päivittäisiin toimintatapoihin ja tekee pitkäkestoista yhteistyötä. Ei-interventionistisessä tutkimuksessa tutkijan suhde case-yritykseen on etäinen, jossa tutkija välttää vaikuttamista ja keskittyy ilmiöiden selittämiseen teoreettisesta näkökulmasta. Tämä case-tutkimus on interventionistinen, sillä tutkija on tehnyt pitkäaikaista ja tiivistä yhteistyötä case-yrityksen kanssa.

Kasanen ja muut (1993) esittävät metodologioiden jaottelun kuvion neljä mukaisesti. Konstruktiivinen tutkimusote sisältää normatiivisia ja empiirisiä piirteitä, jossa tutkija kokeilee luotua konstruktia ja sitoo havainnot teoriaan. Kasanen ja muiden (1993) mukaan toiminta-analyttinen sekä päätöksentekometodologinen tutkimusote muistuttavat osittain konstruktivistista tutkimusotetta.

Sekä päätöksentekometodologisessa että konstruktivisessa tutkimusotteessa teorian tärkeys on keskeistä, minkä lisäksi molemmissa luodaan jotain uutta. Kasanen ja muiden (1993) mukaan päätöksentekometodologisessa tutkimuksessa käytetään deduktiivista menetelmää, kun taas innovatiiviset ratkaisut ovat tyypillisiä konstruktivisessa tutkimuksessa. Suurin ero on konstruktivisen tutkimuksen pyrkimyksessä osoittaa rakennetun ratkaisun käyttökelpoisuus. Myös päätöksentekometodologisessa tutkimuksessa luotu ratkaisu voi olla konstruktivinen, jos käytännön implementointi on onnistunut.

Toiminta-analyttisessä sekä konstruktivisessa tutkimusotteessa käytännönläheisyys sekä lähestyminen toimintaympäristöön on vahvaa (Kasanen & muut, 1993). Case-tutkimus toimii molemmissa tyypillisinä menetelmänä. Merkittävä ero on kuitenkin tutkimuksen tavoitteessa, sillä toiminta-analyttinen tutkimus pyrkii ensisijaisesti ilmiöiden tarkkaan kuvaamiseen ja syvälliseen ymmärtämiseen. Konstruktiivisessa tutkimuksessa puolestaan painotetaan normatiivista ongelmanratkaisua ja uuden käytännöllisen ratkaisun luomista (Kasanen & muut, 1993).

Deskriptiivinen	Teoreettinen	Empiirinen
	Käsiteanalyttinen tutkimusote	Nomoteettinen tutkimusote Toiminta-analyttinen tutkimusote
Normatiivinen	Päätöksentekometodologinen tutkimusote	Konstruktiiivinen tutkimusote

Kuvio 4. Konstruktiiivinen tutkimusote metodologiana (mukaillen Kasanen & muut, 1993).

Konstruktiiivisella tutkimuksella pyritään ratkaisemaan reaali maailman ongelmia yhdessä case-yrityksen työntekijöiden kanssa. Konstruktiiivinen tutkimus on siis interventionistinen tutkimusote, jonka empiirisen työn tavoitteena on luoda konstruktio alkupe-
räiseen ongelmaan. Empiirisellä työllä saavutettu lopputulos on toimittava käytännössä, oltava omaperäinen ja sillä on oltava sekä vahva käytännöllinen että teoreettinen yhteys (Lukka, 2005).

Konstruktiiivinen tutkimus voidaan Labron ja Tuomelan (2003) mukaan jakaa seitsemään vaiheeseen:

1. Käytännön ongelman tunnistaminen
2. Pitkäaikaisen tutkimusyhteistyön varmistaminen case-yrityksen kanssa
3. Kattavan ymmärryksen saavuttaminen aiheesta
4. Teoreettisesti perustellun konstruktion kehittäminen

5. Konstruktion toteutus ja käytännön toimivuus
6. Sovellettavuuden laajuuden arviointi
7. Konstruktion teoreettisen yhteyden osoittaminen


Ensimmäisessä vaiheessa tunnistetaan case-yrityksen käytännön ongelma, jonka ratkaisun nähdään edistävän johtajien päätöksentekoa. Kasanen ja muiden (1993) mukaan ongelmalla tulisi olla teoreettisesti merkittävä ratkaisupotentiaali, mutta kirjallisuudessa ongelmalle ei pitäisi olla ilmeistä ratkaisua. Toisessa vaiheessa selvitetään mahdollisuutta pitkäaikaisesta tutkimusyhteistyöstä case-yrityksen kanssa. Tutkittavan ongelman täytyy olla liiketoiminnan kannalta relevantti, jotta se motivoi johtoa pitkäjänteiseen kehitystyöhön.

Tutkimuksen kolmannessa vaiheessa tutkija perehtyy aiheeseen teoreettisesti ja empiirisesti. Labron ja Tuomelan (2003) mukaan tutkija tarvitsee vankkaa teoriaosaamista voidakseen tehdä päätöksiä tutkimusprosessin aikana. Vaikka innovaatiovaihe voi olla hyvin kokeellinen, aiemman kirjallisuuden tuntemus on tarpeen teoreettisen yhteyden tunnistamiseksi ja analysoimiseksi (Kasanen & muut, 1993). Neljäs vaihe sisältää varsinaisen konstruktion kehittämisen. Intensiivinen havainnointi teoreettisesti ja empiirisesti innovatiiviselle ratkaisulle on ensisijainen piirre, joka erottaa konstruktivisen tutkimuksen muista case-tutkimustyypeistä (Labro & Tuomela, 2003). Innovaatiovaiheen täytyy olla luova ja sen aikana tutkijan ja yrityksen johdon välinen yhteistyö on ratkaisevan tärkeää (Labro & Tuomela, 2003).

Viidennessä vaiheessa konstruktioa kokeillaan käytännössä. Labron ja Tuomelan (2003) mukaan konstruktion kokeiluvaihe on kriittinen, sillä epäonnistunutkin käytännön kokeilu voi osoittautua teoreettisesti mielenkiintoiseksi. Konstruktio on onnistunut, jos se on käytännöllisesti toteuttamiskelpoinen. Kuudennessa vaiheessa tutkija arvioi konstruktion sovellettavuutta muissa organisaatioissa. Viimeisessä vaiheessa osoitetaan konstruktion teoreettinen yhteys. Kasanen ja muut (1993) korostavat teoreettisen yhteyden tärkeyttä, vaikka konstruktioilla itsessään kyettäisiinkin ratkaisemaan ongelma.

Tutkimustulokset täytyy kytkeä aiempaan kirjallisuuteen ja tuloksia täytyy arvioida kriittisesti ja tieteellisesti. Labro ja Tuomela (2003) painottavat, että innovatiivinen ratkaisu teoreettisella varmentamisella erottaa konstruktivisen tutkimuksen puhtaasta konsultointityöstä.

Tässä konstruktivisessa tutkimuksessa laadittu skenaarioanalyysi on monivaiheinen prosessi, jonka läpivienti hyötyy selkeästä prosessimallista. CRISP-DM (Cross Industry Standard Process for Data Mining) prosessimalli on kuusivaiheinen analyttinen datankeruusekä analysointimenetelmä (Mohd Selamat ja muut, 2018). Tässä tutkimuksessa hyödynnetään kyseistä mallia, mikä auttaa hahmottamaan tutkimuksen etenemisprosessia aina toimintaympäristön ymmärtämisestä laskentamallin käyttöönottoon saakka. Kuviossa viisi esitetään mallin eri vaiheet.



Kuvio 5. CRISP-DM malli (Mohd Selamat ja muut, 2018).

Prosessimalli alkaa liiketoiminnan ymmärtämisestä (business understanding), jota sovelletaan tässä tutkimuksessa luvussa viisi, jossa case-yrityksen toimialaa ja markkinaa esitetään. Epäsuorien hankintojen kehitykseen vaikuttavia tekijöitä on paljon, minkä vuoksi on pyrittävä huomioimaan liiketoimintaympäristön olennaisimmat tekijät, jotka

vaikuttavat epäsuorien hankintojen kustannuksiin. Mallin toinen vaihe on datan ymmärtäminen (data understanding), jota käsiteltiin luvussa 5.2 epäsuorien hankintojen kulerien muodossa sekä luvussa 6.1, jossa case-yritykselle luodaan PESTEL-analyysi. Datan esivalmistelu (data preparation) on mallin kolmas vaihe. Esivalmistelu suoritettiin sisäisesti case-yrityksessä. Kolmannessa vaiheessa määriteltiin esimerkiksi tutkimukseen valitut neljä skenaariota. Luoduilla skenaariolla on lähtöolettamuksia, joita valittiin hyödyn-tämällä julkisia tulevaisuus selvityksiin pohjautuvia lähteitä sekä laadittua PESTEL-analyysiä.

Neljäs ja tutkimuksen kannalta olennaisin vaihe on mallintaminen (modeling). Case-yrityksen epäsuorien hankintojen kehitykseen vaikuttaa useat muutostekijät. Näitä muutostekijöitä hyödynnettiin laskentamallissa skenaarioiden taustaolettamusten mukaisesti. Epäsuorien hankintojen kehityksen mallinnus luotiin TIA-analyysiä apuna käyttäen, jota käsiteltiin luvussa 4.2.2 ja mallinnuksen osalta vielä tarkemmin luvussa 6.2.

Viides vaihe on tulosten eli tässä tapauksessa skenaarioiden arviointi (evaluate), joka suoritetaan luvussa seitsemän ja laajemmin case-yrityksessä sisäisesti. Kuudennessa vaiheessa pyritään jatkojalostamaan ja kehittämään (deployment) saatuja skenaarioita sekä pohtimaan mahdollisia vaikutuksia epäsuoriin hankintoihin kohdistuvista strategisista päätöksistä. Niitä analysoidaan tämän tutkimuksen ulkopuolella case-yrityksessä.

6.1 PESTEL-analyysi

Skenaariotyöskentelyssä pyritään ymmärtämään yrityksen toimintaympäristö kokonaisvaltaisesti. Case-yrityksen toimintaympäristöstä voidaan saada kokonaisvaltainen ymmärrys PESTEL-analyysin avulla. PESTEL-analyysi on strateginen työkalu, jolla tarkastellaan yrityksen makroympäristön vaikutuksia yhtiön toimintaan (Vuorinen & Huikkola, 2023). Kirjaimet tulevat sanoista poliittinen, ekonominen, sosiaalinen, teknologinen, ekologinen ja lainsäädännöllinen. Vuorisen ja Huikkolan (2023) mukaan analyysin tarkoituksena on saada hyvä lähtökohta strategiselle tarkastelulle jäsentämällä ulkoiset tekijät.

Vaikka muutoksiin ja trendeihin ei voisi vaikuttaa, on ne kuitenkin tärkeää tiedostaa ja ottaa huomioon.

Tässä tutkimuksessa PESTEL-analyysi on tehty yleisellä tasolla yhtiön makroympäristöstä, sillä yrityksen epäsuorat hankinnat koostuvat lukuisista kulueristä ja kirjanpidon tileistä, joiden tulevaisuuden hintakehitykseen voi vaikuttaa moni eri asia. PESTEL-analyysin muutosvoimien hahmottaminen perustuu useiden tulevaisuusselvityksiin perustuvien lähteiden tietoihin (ks. liite 1). Mainitut muutosvoimat ovat mahdollisia suuria kehityslinjoja, joiden myötä voidaan hahmottaa valittujen skenaarioiden taustaolettamukset.

PESTEL-analyysi on kokonaisuudessaan liitteessä yksi. Seuraavissa alaluvuissa on tiivistettynä selitetty jokaisen kuuden kirjaimen tuloksia yhtiön toimintaympäristöstä. Analyysin tuloksia hyödynnetään skenaarioiden taustaolettamusten valinnassa. Taustaolettamukset skenaarioille on liitteessä kaksi. On kuitenkin huomioitava, että epäsuorien hankintojen kehitykseen vaikuttaa myös sisäiset tekijät. Ne otetaan analyysiin mukaan epäsuorien hankintojen mahdollisten muutostekijöiden muodossa sisäisessä versiossa.

6.1.1 Poliittiset tekijät

Poliittiset tekijät ohjaavat case-yrityksen toimintaa merkittävästi. Suomen markkinoilla toimivan yhtiön toimintaan vaikuttavat ennen kaikkea Suomen valtion ja EU:n tasolla tehtävät poliittiset päätökset.

Keskeisimpiä tekijöitä ovat verotus, ympäristö- ja ilmastopolitiikka, kuin myös EU-lainsäädäntö sekä kuluttaja- ja kilpailupolitiikka. Ajoneuvoverotus vaikuttaa voimakkaasti kuluttajien ostohalukkuuteen. Lisäksi polttoaineveroon liittyvät muutokset ja sähköautoilun tukeminen verohuojennuksin tai latausinfrastruktuurin rakentaminen ohjaavat kuluttajien ajoneuvohankintoja.

Ympäristö- ja ilmastopolitiikassa Suomi noudattaa EU:n päästörajoja ja ilmastotavoitteita, jotka painottavat vähäpäästöisten autojen asemaa. Tämä näkyy käytännössä erilaisina kannustimina esimerkiksi sähköautoja hankkiville. Autokannan nähdään sähköistyvän entisestään, minkä myötä autoliikkeen on vastattava asiakkaiden odotuksiin tarjoamalla monipuolinen valikoima vähäpäästöisiä ajoneuvoja. Hallituksen tulevaisuusselonteon (2024) mukaan EU:n ja Suomen hallituksen tiukentuvat tavoitteet vähentää liikenteen päästöjä ohjaavat autokauppaa kohti vähäpäästöisempiä käyttövoimia. Myös EU-lainsäädäntö ohjaa autonvalmistajia tiukkoihin turvallisuus- ja ympäristöstandardeihin, mikä heijastuu suoraan suomalaisten autoliikkeiden toimintaan.

Kansainvälisellä tasolla Suomen poliittinen ilmapiiri on varsin vakaa. Poliittinen vakaus tukee autoliikkeen ennustettavuutta, vaikka hallitusohjelmien eri painotukset voivatkin nopeasti muuttaa autoilun verotusta tai päästövaatimuksia. Täten on tärkeää, että case-yritys seuraa aktiivisesti poliittista keskustelua.

6.1.2 Ekonomiset tekijät

Autoliikkeen menestykseen voi vaikuttaa ratkaisevasti yleinen taloustilanne, sillä se määrittää sekä kuluttajien ostovoimaa että yrityksen kustannusrakennetta. Mikäli bruttokansantuote (BKT) kasvaa ja työllisyysaste kohenee, kuluttajilla on enemmän käytettävissä olevia varoja. Tämä lisää valmiutta merkittäviin hankintoihin, kuten auton ostoon. Vastaavasti talouden laskusuhdanteessa kysyntä yleensä heikkenee, sillä suuri osa kuluttajista siirtää hankintojaan tulevaisuuteen. Suomen Pankin ennusteen (2024) mukaan talouskasvu on hidasta vuosina 2025–2027, mutta kiihtyy sen jälkeen vähitellen.

Toinen keskeinen taloudellinen elementti on rahoituksen saatavuus ja korkotaso. Koska suuri osa auton ostajista turvautuu rahoituslaitosten tarjoamiin lainoihin tai osamaksusopimukseen, alhainen korkotaso kannustaa auton hankintaan ja elvyttää autokauppaa. Euroopan keskuspankin päätökset ohjauskorosta vaikuttavat suoraan suomalaisiin lainakorkoihin. Myös inflaatiolla on merkittävä roolinsa, sillä yleinen hintojen nousu voi

nostaa autojen hintoja, toimittajien varaosakustannuksia ja myös case-yrityksen työntekijöiden ansioita. Tämä voi hillitä kuluttajien ostohalukkuutta, jos tulojen kasvu ei pysy hintojen nousun tahdissa.

Kaiken kaikkiaan taloudellinen tilanne on vahvasti sidoksissa case-yrityksen kannattavuuteen. Yrityksen menestys edellyttää tarkkaa taloudellisten trendien seuranta ja kykyä sopeutua muuttuvaan korko-, vero- ja kilpailuympäristöön. Kun kuluttajat luottavat talouden kehitykseen ja korkotasot säilyvät suotuisina, niin varsinkin uusien ajoneuvojen myynnin nähdään elyvän. Vastaavasti epävarmoina aikoina autoliikkeet saattavat joutua tiukentamaan kustannuskuria ja optimoimaan valikoimaansa säilyttääkseen kannattavuutensa.

6.1.3 Sosiaaliset tekijät

Yleisen ympäristötietoisuuden lisääntyminen sekä kasvava huoli ilmastosta ovat tekijöitä, jotka vaikuttavat joidenkin kuluttajien arvovalintoihin (Sitra, 2023). Monet saattavat liikumistarpeita pohtiessaan valita päästöttömän tai mahdollisimman päästöttömän vaihtoehdon, kuten sähköauton tai joukkoliikenteen.

Viime vuosikymmenien aikana kaupungistuminen on kasvanut eikä kasvun nähdä loppuvan. Kaupunkien paremmat joukkoliikennepalvelut ja etätyön yleistymisen voivat vähentää perheiden toisen tai kolmannen ajoneuvon tarvetta. Suomen väestön ennustetaan ikääntyvän entisestään, joten iäkkäiden asiakkaiden tarpeet voivat korostaa helppokäyttöisten ajoneuvojen kysyntää.

Sosiaalisissa tekijöissä korostuu myös palvelun laatu ja asiakaskokemus, etenkin kun Suomessa kilpailu autokaupan alalla on kovaa. Nykypäivän kuluttajat odottavat nopeaa, sujuvaa ja ystävällistä palvelua niin verkossa kuin myymälässäkkin. Positiiviset kokemukset leviävät nopeasti, mutta yhtä lailla huonosta palvelusta kertovat kommentit voivat heikentää case-yrityksen mainetta. Tästä syystä laadukas ja kokonaisvaltainen

asiakaskokemus ovat olennaisia piirteitä, joilla autoliike pystyy säilyttämään kilpailukykyä ja rakentamaan luottamuksellisia ja pitkäkestoisia asiakassuhteita. Case-yritys pyrkii olemaan jokaisen suosittelun arvoinen.

6.1.4 Teknologiset tekijät

Case-yrityksen toimintaan vaikuttavia teknologisia tekijöitä on useita. Sähköautojen teknologian kehitys on tällä hetkellä näkyvä trendi, jossa akkujen energiatiheyden kasvu, latausnopeuden parantuminen sekä toimintasäteen piteneminen tekevät sähköautoista yhä houkuttelevamman ja kestävämmän vaihtoehdon perinteisille polttomoottoriautoille. Liikenne- ja viestintäministeriön (2024) mukaan uudet polttoaineet, kuten biopolttoaineet ja synteettiset polttoaineet, tarjoavat potentiaalisia vaihtoehtoja fossiilisille polttoaineille ja voivat vähentää liikenteen päästöjä.

Toinen jo pitkään jatkunut trendi on digitalisaatio ja ennen kaikkea automatisaatio ja tekoäly. Älykkäät liikennejärjestelmät ja datan hyödyntäminen mahdollistavat uusia palveluita ja liiketoimintamalleja, kuten etädiagnostiikan ja personoidut ajokokemukset. Yritysten on investoitava digitaaliseen osaamiseen pysyäkseen kilpailukykyisinä.

Automaatio ja tekoäly asettavat tulevaisuudessa sekä mahdollisuuksia että haasteita. Investoinnit uuden teknologian vaatimiin laitteistoihin, koulutukseen ja tietoturvaan ovat summiltaan merkittäviä, mutta toisaalta oikein hyödynnettynä teknologia voi parantaa kilpailukykyä, tehostaa myyntiprosesseja ja vastata entistä paremmin asiakkaiden vaatimien odotuksiin. Näistä manuaalisten työtehtävien automatisointi nähdään kuitenkin tärkeimpänä liiketoimintaa kehittävänä tekijänä.

Erilaiset teknologiset innovaatiot ja etenkin tekoäly kehittyvät kiihtyvää tahtia. Teknologiset muutokset vaativat yleensä huomattavia investointeja. Case-yrityksen epäsuorat hankinnat ovat kokonaisuudessaan iso kuluerä, joten pienilläkin teknologisilla

parannuksilla voidaan saavuttaa säästöä esimerkiksi havaitsemalla kustannussäästökoh-
teita tekoälyn avulla.

6.1.5 Ekologiset tekijät

Ympäristölliset tekijät tulevat vaikuttamaan voimakkaasti case-yrityksen toimintaan tu-
levaisuudessa. Suomen hallitus on asettanut Suomelle tavoitteeksi olla hiilineutraali vuo-
teen 2035 mennessä (Hallituksen tulevaisuusselonteko, 2024). Sen lisäksi Suomi on aset-
tanut tavoitteeksi liikenteestä aiheutuvien päästöjen puolittumisen vuoteen 2030 men-
nessä. Näiden tavoitteiden saavuttamiseksi Suomen autokannan on muututtava vähä-
päästöisemmäksi.

Uusiutuvien energialähteiden osuuden kasvattaminen on keskeinen osa ilmastotavoit-
teiden saavuttamista. Sähköautojen yleistyessä on tärkeää, että sähköntuotanto perus-
tuu yhä enemmän uusiutuviin energialähteisiin, jotta sähköautojen käytöstä saatavat
päästövähennykset toteutuvat. Kiertotalous on nouseva trendi, joka koskee myös auto-
liikkeitä. Autojen kierrätys ja uudelleenkäyttö, sekä materiaalien tehokas hyödyntäminen
vähentävät luonnonvarojen kulutusta ja ympäristövaikutuksia. Erityisesti sähköautojen
akkujen kierrätys on tärkeä ympäristönäkökulma, mikä autoliikkeiden on otettava huo-
mioon.

Kuluttajien ympäristötietoisuus kasvaa jatkuvasti, minkä vuoksi yhä useammat asiakkaat
arvostavat ympäristöystävällisiä vaihtoehtoja. Tämä luo case-yritykselle mahdollisuuksia
tarjota vähäpäästöisiä autoja, energiatehokkaita palveluita ja ympäristövastuullisia toi-
mintatapoja. Tulevaisuudessa case-yritys on myös velvollinen luomaan toiminnastaan
kestävyyseraportti EU:n kestävyysraportointistandardien mukaisesti tilinpäätöksen yhtey-
dessä. Kestävyysteemoihin paneutuminen tulee lisääntymään tulevaisuudessa ja täten
todennäköisesti vaatimaan case-yritykseltä investointeja, kun tietoja kerätään, kootaan
ja varmennetaan.

Ekologiset tekijät ovat merkittävä osa case-yrityksen toimintaa tulevaisuudessa, mikä voi aiheuttaa haasteita, mutta myös mahdollisuuksia, jos case-yritys onnistuu yhdistämään liiketoimintansa ympäristövastuuseen entistä enemmän.

6.1.6 Lainsäädännölliset tekijät

Case-yrityksen toiminta on tiiviisti sidoksissa lainsäädäntöön, joka ohjaa kilpailua, kuluttajansuojaa, markkinointia kuin ympäristövastuutakin. Suomessa kuluttajansuoja on varsin vahva ja viranomaiset puuttuvat herkästi laiminlyönteihin. Myös kilpailulainsäädäntö vaikuttaa toimintaan, sillä Suomen ja EU:n kilpailusäädökset kieltävät hintasopimukset ja määräävän markkina-aseman väärinkäytön, minkä vuoksi autoliikkeiden on toimittava avoimesti ja reilusti toisiaan kohtaan.

Case-yrityksen on otettava huomioon myös työntekijöiden oikeuksiin ja työsuojeluun liittyvä lainsäädäntö, kuten työehtosopimukset ja turvallisuusmääräykset, sekä erilaiset ajoneuvojen katsastukseen, rekisteröintiin ja verotukseen liittyvät lait ja asetukset. Näiden lisäksi EU:n yleinen tietosuojasetus (GDPR) velvoittaa käsittelemään asiakkaiden henkilötietoja turvallisesti ja luottamuksellisesti, mikä korostaa tietoturvakäytäntöjen merkitystä digitaalisissa järjestelmissä.

Monipuolinen ja muuttuva lainsäädäntö luo ehdot autoliikkeen päivittäiselle toiminnalle. Siksi case-yrityksen on seurattava aktiivisesti lainsäädännön muutoksia ja noudatettava veloitteita johdonmukaisesti, jotta se voi säilyttää kuluttajien sekä viranomaisten luottamuksen, ja täten välttää oikeudelliset riskit. Vaikka toimintaa ohjaavat puitteet voidaan kokea tiukkoina, ne myös edesauttavat kuluttajien luottamuksen rakentumista ja pitkäjänteistä toimintaa markkinoilla.

6.2 TIA-menetelmä

Jatkuvassa muutoksessa tulevaisuuden tapahtumia on epävarmuuden vallitessa lähes mahdoton ennustaa. Luvussa 4.2.2 käsitelty TIA-menetelmä on yksi käytetyimmistä tulevaisuuden ennakointimenetelmistä sen selkeän lähestymistavan vuoksi. Sen hyöty nähdään siinä, että se auttaa varautumaan sekä odotettavissa oleviin kehityskulkuihin että arvaamattomiin yllätyksiin.

Tässä tutkimuksessa TIA-menetelmä luodaan kahden päävaiheen avulla. Aluksi määritellään historiallisen datan pohjalta perusskenaario, jossa tulevaisuuden epäsuorat hankinnat nähdään kehittyvän yllätysvapaassa ympäristössä. Tässä tutkimuksessa perusskenaario saadaan käyttämällä case-yrityksen epäsuorien hankintojen euromäärää vuosilta 2020–2024.

Toisessa vaiheessa skenaarioille perusskenaariota lukuun ottamatta valitaan trendit ja muutostekijät, joiden oletetaan vaikuttavan epäsuorien hankintojen hintojen kehitykseen. Jokaiselle trendille luodaan todennäköisyydet sille, että ne tapahtuvat tiettyinä ajanjaksoina. Trendien mahdolliset vaikutukset hintojen kehitykseen arvioidaan myös. Case-yritykselle TIA:n hyödyntäminen on etu, sillä se ei sido organisaatiota yhteen ainoaan ennusteeseen, vaan näyttää vaihtoehtoisia kehityspolkuja. Sen avulla voidaan joustavasti mallintaa useita skenaarioita ja vaihtaa eri trendien vaikutuskertoimia.

TIA-menetelmää on kuitenkin myös kritisoitu siitä, että trendien todennäköisyyksien ja vaikutusten arviointi on usein asiantuntijoiden mielipiteiden varassa. Tämä voi johtaa virheelliseen ennakointiin, jos asiantuntijoilla on puutteellista tietoa tai ennakoasenteita (Agami & muut, 2008). Myös aikajakson valinta nähdään haastavana, sillä mitä pidemmälle tulevaisuuteen katsotaan, sitä enemmän epävarmuus kasvaa. Onkin tärkeää määritellä selkeästi, missä ajassa TIA-menetelmän halutaan tuottavan tietoa.

Kokonaisuudessaan TIA-menetelmän käyttö ei tuo absoluuttista totuutta epäsuorien hankintojen hintojen kehityksestä, mutta sen avulla saadaan rakennettua laskentamalli,

jolla voidaan mallintaa eri skenaarioita, joissa huomioidaan eri tapahtumien vaikutukset. Analyysin avulla saadaan mahdolliset muutokset näkyviksi, ja parhaassa tapauksessa se ohjaa koko organisaatiota jatkuvaan tulevaisuusorientoituneeseen ajatteluun.

6.3 Laskentamallin laadinta

Tässä tutkimuksessa skenaariotyöskentelyn olennaisin vaihe on laskentamallin laadinta, jonka avulla saadaan epäsuorille hankinnoille euromääräiset luvut. Laskentamallin avulla voidaan mallintaa vaihtoehtoisia skenaarioita epäsuorien hankintojen kehitykselle. Tutkimukseen mallinnetaan laskentamallilla neljä skenaariota. On huomioitava, että epävarmuus on aina läsnä, eikä mistään laskentamallista voida poistaa epävarmuutta. On kuitenkin mahdollista luoda mahdollisimman realistisia tulevaisuudenkuvia, jos pyritään huomioimaan sekä ulkoisia että sisäisiä tekijöitä. Ulkoiset tekijät tulevat ilmi aiemmin laaditusta PESTEL-analyysistä ja sen kautta johdetuista skenaarioiden taustaolettamuksista. Sisäisiä tekijöitä käsitellään sisäisesti palautettavassa versiossa. Tässä tutkimuksessa käsitellään ainoastaan ulkoisten tekijöiden vaikutuksia.

Tutkimuksen laskentamalli on laadittu Microsoft Officen Exceliä, Python ohjelmointikieltä sekä OpenAI:n ChatGPT:n o4-mini-high versiota käyttäen. Laskentamallin laadinnan vaiheet voidaan jakaa viiteen osaan:

1. Epäsuorien hankintojen datan kerääminen ja mallintaminen

Case-yrityksen järjestelmästä kerätään epäsuorien hankintojen data kirjanpitoileittäin vuosilta 2020–2024. Data mallinnetaan Excelissä Pythonille luettavaan muotoon.

2. Skenaarioissa esiintyvien tapahtumien määrittely

Perusskenaariota lukuun ottamatta jokaiselle skenaariolle valitaan tapahtumat ja niiden ilmenemisen todennäköisyydet ja vaikutuskertoimet tietyllä ajanjaksolla. Nämä on

laadittu case-yrityksessä sisäisesti. Esimerkiksi talouskasvuskenaariossa henkilöstökulujen voidaan olettaa kasvavan, kun uusia työntekijöitä rekrytoidaan liiketoiminnan kasvussa. Tämän tapahtuman todennäköisyys voisi olla esimerkiksi 95 prosenttia, vuosittainen vaikutus plus kaksi prosenttia ja ajanjakso 2027–2031.

3. Monte Carlo -simulaation hyödyntäminen

Laskentamallissa käytetään Monte Carlo -simulaatiota, jonka avulla voidaan mallintaa eri tapahtumien todennäköisyyden vaikutusta mahdollisimman tarkasti (Holman & Hacherl, 2023). Laskentamallissa toistetaan jotain tapahtumaa niin monta kertaa, että saadaan oletettava hintakehitys skenaarioille. Hyvä käytännön esimerkki aiheesta on kolikonheitto. Tiedetään, että kolikkoa heittäessä voi saada joko kruunan tai klaavan. Jos kolikkoa heitetään kymmenen kertaa, niin on melko todennäköistä saada esimerkiksi kolme kertaa klaava ja seitsemän kertaa kruuna eli suhde on 70/30 eikä 50/50. Kun tapahtuma toistetaan lukuisia kertoja, kuten 10 000 kertaa, niin päästään kuitenkin lähemmäs todennäköistä suhdetta, kuten alla olevasta kuvan kaksi Python-koodista näkee. Jokaisen skenaarion kohdalla hyödynnetään Monte Carlo -simulaatiota, jotta oletukset tapahtumien todennäköisyyksistä toteutuvat.

```


▶ import numpy as np

def coin_toss_simulation(num_tosses):
    # 0 = klaava, 1 = kruuna
    results = np.random.choice([0, 1], size=num_tosses, p=[0.5, 0.5])
    heads = np.sum(results == 0)
    tails = np.sum(results == 1)
    return heads, tails

# Simulaatio 10 heitolla:
heads_10, tails_10 = coin_toss_simulation(10)
print(f"10 heitolla: Klaavoja = {heads_10}, Kruunuja = {tails_10}")

# Simulaatio 10 000 heitolla:
heads_10000, tails_10000 = coin_toss_simulation(10000)
print(f"10 000 heitolla: Klaavoja = {heads_10000}, Kruunuja = {tails_10000}")

```

 10 heitolla: Klaavoja = 3, Kruunuja = 7
 10 000 heitolla: Klaavoja = 5003, Kruunuja = 4997

Kuva 2. Pythonilla luotu Monte Carlo -simulaatio kolikonheiton yhteydessä.

4. Historiatatan perusteella yllätysvapaan ympäristön määrittely

Pythonin avulla luodaan perusskenaario epäsuorien hankintojen kehitykselle. Perusskenaariossa luodaan historiatatalla lineaarinen trendi kunkin kuluerän osalta. Perusskenaariossa ei oleteta tapahtuvan odottamattomia muutoksia, vaan se heijastaa pelkästään historian trendiä. Historiatatalla ennustettaessa käytetään lineaarisen regressiomallin kaavaa $Y = a + bX$, jossa Y on epäsuorien hankintojen ennustettu kuluerän määrä, a on mallin vakiotermin eli tässä tapauksessa epäsuorien hankintojen määrä edellisvuonna, b on trendikerroin ja X on ajallinen muuttuja eli vuosi tässä tapauksessa.

Pythonille syötetään epäsuorien hankintojen määrät Excel-muodossa, minkä jälkeen sovitetaan kustakin neljästä kuluerästä lineaarinen trendi. Vaikka perusskenaario ei huomioi markkinoiden äkillisiä muutoksia, sen avulla saadaan kuitenkin vankka lähtökohta skenaarioanalyysille, sillä se perustuu historiassa havaittuun kehitykseen.

5. Graafinen ja numeerinen vertailu perusskenaarion ja muiden skenaarioiden välillä

Mallintamisen avulla voidaan vertailla skenaarioita sekä numeerisesti että graafisesti. Skenaariot esitetään pylväskaavioina, joista nähdään epäsuorien hankintojen määrä vuositasolla. Jokaisesta mallinnetusta skenaariosta luodaan vertailu perusskenaarioon, jotta havainnollistetaan vuosittain kokonaiskustannukset sekä kustannuserot näiden skenaarioiden välillä.

6.4 Skenaarioanalyysi ja skenaarioiden vaikutus päätöksentekoon


Vuorisen ja Huikkolan (2023) mukaan tarkasteltavat skenaariot ovat tyypillisesti pessimistisiä, optimistisia ja todennäköisiä. Näiden lisäksi tähän tutkimukseen valitaan perusskenaario, jossa oletetaan epäsuorien hankintojen kehityksen jatkuvan täysin menneisyyden perusteella. Talouskasvuskenaario kuvaa optimistista skenaariota, taantumaskenaario pessimististä skenaariota ja Sähkö-Suomi-skenaario todennäköistä skenaariota. Kestävän kehityksen ja digitalisaation edistäminen nähdään jatkuvan Euroopassa ja Suomessa, minkä vuoksi Sähkö-Suomi-skenaario nähdään todennäköisenä tulevaisuuskuvana. Näiden ryhmittelyjen myötä pyritään tuomaan skenaarioihin vaikuttavat ulkoiset tekijät selkeämmin esille.

Seuraavissa alaluvuissa kuvataan tarkemmin tutkimukseen valitut skenaariot. Skenaarioissa case-yrityksen epäsuorien hankintojen kehitystä verrataan graafisesti perusskenaarioon nähden. Skenaarioiden taustaolettamukset pohjautuvat luotuun PESTEL-analyysiin sekä julkisiin tulevaisuusselvityksiin, jotka löytyvät liitteistä yksi ja kaksi. Taustaolettamuksien avulla voidaan painottaa kunkin skenaarion kehityssuuntaa. Taustaolettamuksien lisäksi skenaarioiden kehitykseen vaikuttavat kunkin neljän kuluerän mahdolliset muutostekijät. Nämä muutostekijät sisältävät sekä sisäisiä että ulkoisia tekijöitä, minkä vuoksi ne on jätetty tämän tutkielman ulkopuolelle liikesalaisuuksiin vedoten sisäiseen versioon.

Liikesalaisuuksien takia on painotettava, että epäsuorien hankintojen lähtötaso sekä skenaarioiden arvot ovat kuvitteellisia ja niille on luotu vain suuntaa antava yhteys case-yrityksen todellisiin lukuihin nähden. Myös tapahtumien todennäköisyydet ovat tutkijan itsensä määrittelemiä, mikä korostaa kuvioiden riippumattomuutta case-yrityksen mielipiteistä. Tässä tutkimuksessa epäsuorat hankinnat esitetään yhtenäisenä eränä, jotta yhtiön kulurakenne ei selviä lukijalle. Sisäisesti palautettava versio tulee sisältämään todelliset luvut sekä neljä kuluerää itsenäisinä erinä. Esimerkiksi, jos ajatellaan kuviossa viisi kaikkien neljän kuluerän osuuden olevan saman verran eli 25 prosenttia, niin lähtötason ollessa yhdeksän miljoonaa jokaisen kuluerän osuus olisi 2,25 miljoonaa. Täten case-yritys havaitsee jokaisen kuluerän kehityksen erikseen tulevina vuosina.

On myös painotettava, että minkään seuraavan neljän skenaarion ei ole tarkoitus olla todennäköisempi verrattuna muihin skenaarioihin. Skenaariot on luotu poikkeamaan toisistaan merkittävästi, mutta samanaikaisesti jokainen niistä on mahdollinen kuvaus tulevaisuuden epäsuorista hankinnoista.

6.4.1 Perusskenaario




Kuvio 6. Epäsuorien hankintojen kehitys perusskenaariossa.

Perusskenaario perustuu oletukseen, että tulevaisuuden kehitys pohjautuu historialliseen trendiin. Historiallinen data on vuosilta 2020–2024. Perusskenaarion avulla voidaan ymmärtää, miten aiempien vuosien pohjalta tehdyt ennusteet poikkeavat niistä skenaarioista, joissa otetaan huomioon erilaisia trendivaikutuksia. Täten voidaan havainnollistaa, miten eri oletetut tapahtumat vaikuttavat kehitykseen verrattuna perinteiseen lineaariseen trendiin. Perusskenaariossa ei siis oleteta ulkoisissa eikä sisäisissä tekijöissä tapahtuvan muutoksia.

Kuviossa kuusi on havainnollistettu epäsuorien hankintojen kehitys perusskenaariossa. Kaikissa neljässä skenaariossa perusskenaarion epäsuorat hankinnat esitetään sinisinä pylväskaavioina ja vuoden 2024 lähtötaso oranssilla viivalla. Tutkivan skenaarion epäsuorat hankinnat esitetään vihreinä pylväskaavioina ja ero tutkivan skenaarion ja perusskenaarion välillä vaaleansinisellä viivalla.

Historiadatasta johdettu lineaarinen trendi on perusskenaariossa nouseva. Hankintojen lähtötaso vuonna 2024 on yhdeksän miljoonaa euroa, ja historiadatan perusteella ne nousevat noin 14 miljoonaan euroon vuoteen 2034 mennessä. Kehityksen perusteella epäsuorien hankintojen määrä kasvaa yli 50 prosenttia seuraavan kymmenen vuoden aikana.

6.4.2 Talouskasvuskenaario



Kuvio 7. Epäsuorien hankintojen kehitys talouskasvuskenaariossa.

Talouskasvuskenaario perustuu oletukseen, että Suomen talouskasvu lähtee kasvuun, mikä lisää myös case-yrityksen tuotteiden kysyntää. Viime vuosina käytetyille ajoneuvoille on ollut enemmän kysyntää kuin uusille ajoneuvoille. Talouskasvuskenaariossa tähän tulee muutos, kun kuluttajien ostovoima kasvaa ja usko omaan taloudentilaan koheenee, mikä johtaa uusien ajoneuvojen kaupan elpymiseen. Suomessa ja EU:ssa vallitsee vakaa poliittinen tilanne, eikä kauppasotia synny. Täten tuontiajoneuvojen saannille ei nähdä kehittyvän haasteita.


Yleisesti talouskasvun nähdään kasvattavan ympäristön kuormitusta, mutta tulevaisuudessa kasvun edellytykselle vaaditaan liiketoimintaa, joka minimoi ympäristökuormitusta. Täten ajoneuvojen sähköistymisen kehitys jatkuu. Tästä huolimatta energiantuotannon nähdään olevan Suomessa monipuolista, ja fossiiliset polttoaineet sekä polttomoottoriajoneuvot ovat edelleen merkittävässä roolissa.

Talouskasvuskenaariossa kaikki neljä kuluerää nousee. Kysynnän ja liikevaihdon kasvussa myös operatiiviset kulut kasvavat. Jotta kysyntä vastaa tarjontaa, on liiketoimintaa laajennettava. Täten liiketoiminnan kasvun myötä rekrytoidaan lisää työntekijöitä.

Uusien työntekijöiden palkkojen lisäksi automyyjien provisiopalkkaus on merkittävä henkilöstökuluja kasvattava erä, sillä myynnin kasvaessa voidaan automyyjien provisiopalkkioidenkin olettaa kasvavan. Vuokrat ja kiinteistökulut kasvavat vuokrasopimusten indeksikorotusten sekä toimitilojen huoltokustannusten nousun johdosta. Kasvavan kilpailun myötä jokainen yhtiö haluaa saada näkyvyyttä, minkä vuoksi markkinointikulut kasvavat.

Kuviossa seitsemän on havainnollistettu epäsuorien hankintojen kehitys talouskasvuskenaariossa. Mallinnuksen myötä yhtiön kulujen nähdään kasvavan perusskenaarioon nähden joka vuosi ja erityisesti vuodesta 2028 eteenpäin erotus perusskenaarion ja talouskasvuskenaarion välillä kasvaa entisestään. Kasvanut kysyntä sekä liikevaihdon kasvu johtavat suurempiin epäsuoriin hankintoihin, mikä näkyy talouskasvuskenaariopylväiden korkeana kasvuna. Kuluttajien ostovoiman elpyminen ja kysynnän lisääntyminen pakottavat investoimaan henkilöstöön ja toimitilojen ylläpitoon, jolloin kustannukset kasvavat entisestään. Samalla markkinointipanostukset voimistuvat kilpailun kiristyessä. Täten talouskasvuskenaariossa vuonna 2034 yhtiön epäsuorien hankintojen määrä on kasvanut 16 miljoonaan euroon, mikä on noin 1,9 miljoonaa euroa enemmän kuin perusskenaariossa.

6.4.3 Taantumaskenaario



Kuvio 8. Epäsuorien hankintojen kehitys taantumaskenaariossa.

Taantumaskenaariossa Suomi elää nollakasvun aikaa. Talouden näkymät ovat heikot, ja työttömyyden kasvu sekä työntekijöiden mielenterveysongelmat aiheuttavat huolta. Kaupungeissa yksityisautoilu vähenee ja julkisen liikenteen suosio kasvaa. Autokannan sähköistymistavoite ei vaikuta todennäköiseltä. Valtio ei lisää kannusteita sähköautojen hankintaan, ja autoteollisuudessa investoinnit uusiin teknologioihin vähenevät. Sen sijaan keskitytään kustannustehokkaisiin ratkaisuihin.


Valtion talouden kannalta pahimpia tilanteita on stagflaatio, jossa on valloillaan kolme tapahtumaa: erittäin hidas talouskasvu, inflaation kiihtyminen ja työttömyyden kasvu (Eloranta ja muut, 2024, s. 138). Taantumaskenaariossa Suomen oletetaan joutuvan stagflaatioon, mikä vaikuttaa merkittävästi kuluttajien ostovoimaan. Suomen BKT ei kasva ja inflaatio nostaa korkotasoa, jonka vuoksi kuluttajat eivät suosi kalliita hankintoja, kuten ajoneuvon ostoa. Kuluttajat alkavat suosia edullisempia ratkaisuja, mikä johtaa ajoneuvojen kysynnän ja case-yrityksen liikevaihdon laskuun.

Taantumaskenaariossa case-yrityksessä on havaittavissa heikkoja näkymiä ajoneuvojen myynnin suhteen. Yhtiön on haastavaa kattaa kuluja liikevaihdon laskiessa. Kiihtyvä

inflaatio nostaa useiden raaka-aineiden ja palveluiden hintoja, mikä edelleen lisää kustannuspaineita. Operatiivisten kustannusten ollessa muuttuvia kuluja, on selvää, että ne laskevat liikevaihdon laskun seurauksena. Skenaariossa oletetaan yhtiön joutuvan pakon edessä irtisanomaan työntekijöitään taloudellisista syistä ja myös luopuvan kannattamattomista toimipisteistä. Täten myös henkilöstökulut sekä vuokrat ja kiinteistökulut laskevat.

Taantumaskenaariossa epäsuorien hankintojen kehitys jää selvästi perusskenaarion tasosta. Vaikka inflaation myötä case-yrityksen toimittajien hinnat nousevat, niin kulut laskevat ajoneuvojen kysynnän ollessa heikkoa. Lähtötasoon verrattuna kulut pysyvät lähes samalla tasolla tulevana vuosina. Kuviosta kahdeksan nähdään, kuinka epäsuorien hankintojen määrä pysyy matalammalla tasolla tai jopa laskee joinakin vuosina verrattuna perusskenaarion jatkuvaan nousuun. Vuonna 2034 epäsuorien hankintojen määrä on noin 4,5 miljoonaa euroa vähemmän kuin perusskenaariossa. Yritys joutuu turvautumaan kustannusten leikkauksiin ja prosessien tehostamiseen, jotta se pystyisi säilyttämään kannattavuutensa. Taloustilanne elpyy vuonna 2032, minkä seurauksena ajoneuvojen myynti kasvaa. Myös case-yrityksen kulut lähtevät nousuun talouden elpymisen myötä.

6.4.4 Sähkö-Suomi-skenaario



Kuvio 9. Epäsuorien hankintojen kehitys sähkö-Suomi-skenaariossa.

Sähkö-Suomi-skenaarion oletuksena on Suomen entistä nopeamman autokannan sähköistymisen lisäksi tekoälyn, robotiikan ja automatisaation kiihtyvä integrointi osaksi yritysten liiketoimintaa. EU:ssa ja Suomessa toimet päästöjen vähentämiseksi lisääntyvät ja talouskasvua pyritään saavuttamaan ekologisesti kestävällä tavoilla. Suomella on vahva tahtotila edistää sähköistymistä ja kestävä kehitys on Suomessa operoivien suur yritysten liiketoiminnan keskeisin ajuri. Suomen hallitus on sitoutunut puolittamaan kotimaan liikenteen kasvihuonekaasupäästöt vuoteen 2030 mennessä. Suomi myös tavoittelee hiileneutraaliutta vuoteen 2035 mennessä. Näiden tavoitteiden myötä skenaariossa oletetaan, että hallitus asettaa autoliikkeille sähköautojen myyntiä edistäviä toimia.

Skenaariossa Suomen hallitus lisää kannusteita sähköautojen hankintaan, mikä johtaa sähköautojen kysynnän voimakkaaseen kasvuun. Ympäristötietoisuus ohjaa kuluttajien ostopäätöksiä. Sen myötä case-yrityksen henkilöstöä on koulutettava ja uusia työntekijöitä rekrytoitava täydentämään uudenlaisen osaamisen tarvetta. Esimerkiksi huoltomekaanikkojen työnkuva muuttuu, kun huollettavana on polttomoottoriajoneuvojen sijaan sähköautoja. Henkilöstökulujen oletetaan siis kasvavan. Skenaariossa hallituksen oletetaan myös asettavan myyntirajoja korkeapäästöisille ajoneuvoille, mikä entisestään nopeuttaa autokannan sähköistymistä. Täten sähköautojen latauspisteitä hankitaan lisää

yrittäjien jokaiselle toimipisteelle. Fossiilisia polttoaineita verotetaan entistä raskaammin ja niiden käyttö vähenee huomattavasti. Sähköautojen akkujen ja muiden osien kysyntä ylittää tarjonnan, mikä nostaa yhtiön operatiivisia kuluja. Sähköautojen yleistyessä myös markkinointikulut kasvavat, sillä kilpailu sähköautojen myynnistä kiristyy.

Case-yritys investoi voimakkaasti digitalisaation jatkuvaan murrokseen, mikä nostaa IT-kuluja 2025–2030. Näiden investointien tavoitteena on parantaa operatiivista tehokkuutta ja automatisoida liiketoimintaprosesseja. Hallituksen vuoden 2030 liikennepäästövähennystavoite on saavutettu vuonna 2030 tai vaihtoehtoisesti sitä on siirretty myöhempään ajankohtaan. Vuoden 2030 aikana investoinnit tekoälyyn ja automatisaatioon alkavat tuottaa kustannussäästöjä. Automyyjien työtehtäviä onnistutaan automatisimaan tehokkaasti, minkä myötä työaika vapautuu entistä enemmän itse myyntiprosessiin. Automatisoinnin myötä toimipisteissä on enemmän myyjiä kuin kysyntää, mutta yritys ei irtisano henkilöstöään. Sen sijaan case-yritys mukauttaa rekrytointistrategiansa siten, ettei uusia työntekijöitä palkata niiden tilalle, jotka siirtyvät pois yrityksestä. Tämä luonnollinen työntekijöiden vähennys johtaa henkilöstökulujen laskuun.

Kuvioon yhdeksän on havainnollistettu epäsuorien hankintojen kehitys tässä skenaariossa. Edellä mainittujen tapahtumien myötä kulut lähtevät kasvuun aina vuoteen 2030 saakka, jolloin eroa perusskenaarioon on kertynyt yli 2,5 miljoonaa euroa. Vuodesta 2031 lähtien saavutetaan kustannussäästöjä työtehtävien merkittävien automatisointien myötä. Automyyjien määrän nähdään vähenevän keskimäärin noin yhdellä per toimipiste, olettaen ajoneuvojen kysynnän pysyvän vuoden 2024 tasolla. Tekoälyn ja automatisointien hyödyntämisen myötä case-yritys onnistuu vähentämään kulujaan vuosi vuodelta vuosina 2031–2034, ja lopulta Sähkö-Suomi-skenaariion vuoden 2034 arvo asettuu perusskenaariota pienemmäksi.

6.4.5 Skenaarioiden rooli päätöksenteossa

Aikanaan skenaarioita hyödynnettiin liiketoiminnan suunnittelua avustavana ennustemenetelmänä, mutta skenaarioanalyysiin on lisätty viime vuosina monipuolisempia strategisen johtamisen menetelmiä epävarmuuden ja nopeiden muutosten lisääntyessä (Vuorinen & Huikkola, 2023). Skenaarioiden hyödyntäminen nähdään nimenomaan päätöksentekoa ja ennakointia auttavana menetelmänä. Organisaatioiden on tehtävä päätöksiä vailla varmaa tietoa tulevaisuudesta. Tähän ongelmaan skenaariotyöskentely tuo helpotusta, mutta se vaatii sen, että skenaarioita hyödynnetään päätöksenteossa nykyhetkessä, eikä skenaarioiden mahdollista toteutumista vain odoteta.

Tyypillisesti yrityksen laatimat strategiat koskevat keskipitkän aikavälin suunnitelmia, kun skenaarioissa puolestaan tulevaa tutkitaan pitkällä aikavälillä. Mannermaan (2004, s. 193) mukaan yleinen ongelma on, ettei skenaarioita osata yhdistää strategiaan. Skenaariotyöskentely mielletään usein erilliseksi projektiksi, jonka tuloksia ei juurikaan hyödynnetä varsinaisissa strategisissa valinnoissa. Sen välttämiseksi yrityksen johdon on tärkeää määritellä, miten laadittujen skenaarioiden näkemykset voivat tukea strategian laatimista ja sen jatkuvaa päivittämistä.

Yritykset eivät voi estää toimintaympäristön tulevaisuuden muutosta. Kamenskyn (2014, s. 21) mukaan yritysten kyvyt reagoida muutokseen vaihtelee hyvin paljon. Hän jakaa organisaatiotyyppit viiteen osaan:

1. Muutos on jo tapahtunut, mutta organisaatio ei ole siitä tietoinen.
2. Muutos on tapahtunut, organisaatio huomaa sen, mutta ei käsitä eikä reagoi siihen.
3. Muutos on tapahtunut, organisaatio tiedostaa sen ja ymmärtää sen merkityksen, mutta ei kykene tai halua sopeutua.
4. Organisaatio havaitsee muutoksen tapahtuneen, ymmärtää sen vaikutukset ja muuttaa toimintaansa.
5. Organisaatio ennakoi tulevia muutoksia ja kääntää ne edukseen.

Kamenskyn (2014, s. 21) mukaan yritys voi pysyä pitkällä aikavälillä kilpailussa mukana ainoastaan ryhmissä neljä ja viisi. Muut ryhmät häviävät markkinoilta ennemmin tai myöhemmin. Mitronen ja Raikaslehto (2019) puolestaan esittävät yritysten toimintatavoille kolmen horisontin mallia, jossa ensimmäisessä horisontissa keskitytään nykyisen liiketoiminnan kehittämiseen, toisessa uusien liiketoimintojen kasvattamiseen ja kolmannessa uusien ideoiden ja kokeilujen luomiseen. Suomalaiset yhtiöt ovat vahvoja horisontissa yksi, mutta toinen ja kolmas horisontti aiheuttavat haasteita. Olisi tärkeää tasapainotella horisonttien välillä, sillä ilman laadukkaita operatiivisia prosesseja visionäärinen strategia jää toteutumatta, kun taas pelkkä operatiivinen suorituskyky ei riitä tuottamaan kestävästä menestystä ilman strategista suuntaa (Mitronen & Raikaslehto, 2019).

Skenaarioiden analysoinnin onnistuminen vaatii eri osastojen työntekijöiden mukanaoloa prosessissa. Siten saadaan syvällistä ymmärrystä skenaarioihin vaikuttavista tekijöistä (Bresman, 2013). Tämän vuoksi epäsuorien hankintojen mahdolliset muutostekijät kerättiin case-yrityksen työntekijöiltä, joilla oli ymmärrystä kuluerän tuotteista tai palveluista. On tärkeää kuulla useaa eri tahoja, mutta skenaariotyön onnistumiseksi vielä tärkeämpää on johdon aktiivinen sitoutuminen ja asenne tulevaisuutta ajatellen (Meyero-witz, 2018). Epäsuorien hankintojen merkitys on korostunut viime vuosina muun muassa teknologisen kehityksen sekä kestävästä kehityksen vaatimuksien myötä. Case-yritys on velvollinen luomaan tulevaisuudessa EU:n vaatima kestävyysraportti, minkä nähdään kasvattavan epäsuoria kustannuksia. Yritysten epäsuorien hankintojen määrän nähdään kasvavan myös tulevaisuudessa. Tunnistettujen skenaarioiden kautta on mahdollista siirtyä päätöksenteossa yhä proaktiivisempaan suuntaan, ainakin epäsuorien hankintojen osalta.

Tässä tutkimuksessa keskityttiin luomaan skenaarioita epäsuorien hankintojen kehitykselle ennakoiden pääosin ulkoisten tekijöiden vaikutuksia. Tutkimuksessa hyödynnettiin ennakoivaa matemaattista mallinnusta, jotta skenaariot olisivat luotettavia ja helpommin perusteltavissa. Skenaarioiden avulla case-yrityksen toimintaa ja johdon

päätöksentekoa voidaan parantaa. Tulevaisuus on kuitenkin epävarmaa, ja skenaariot ulottuvat usein pidemmälle kuin yritysten varsinainen strategia, joka luodaan noin 3–5 vuoden päähän. Jotta skenaariotyöskentely toimii parhaalla mahdollisella tavalla päätöksenteon tukena, on sitä jatkuvasti muutettava.

7 Yhteenveto ja johtopäätökset

7.1 Yhteenveto

Autoalaan kohdistuu tällä hetkellä sähköistymisen myötä merkittävää murrosta, joten kyseisellä toimialalla toimivaan case-yritykseen nähtiin kiinnostavana luoda tulevaisuustutkimukseen perustuva tutkielma. Tämän tutkimuksen tavoitteena oli selvittää, miten case-yritys voi saada data-analytiikan avulla kustannussäästöjä hankinnoista. Tavoitteena oli myös data-analytiikan osa-alueen ennakoivan analytiikan avulla luoda case-yritykselle skenaarioita sen epäsuorien hankintojen kehityksestä vuosina 2025–2034.

Tutkimuksen toisessa luvussa esitettiin epäsuorien hankintojen käsite sekä erilaisia hankintastrategioita. Kirjallisuuden perusteella todettiin, että erilaisista pienistä hankinnoista voi kertyä merkittävä kokonaisuus, joka vaikuttaa yritysten kannattavuuteen. Yritysten on luotava hankintastrategiat ennen hankintojensa syvällisempää tutkimista. Hankinnat tulisi luokitella hankintakategorioittain esimerkiksi luvussa esitetyn Kraljicin matriisin mukaan, mikä auttaa analysoimaan kuluja systemaattisemmin.

Kolmannessa luvussa tutkittiin data-analytiikan tasoja sekä niiden merkitystä kustannussäästöjen havainnoinnissa. Tutkimuksessa painotettiin eniten ennakoivaa analytiikkaa, jonka myötä voidaan ennakoida historiatatan sekä kehittyneiden analytiikkatyökalujen avulla mahdollisia säästömahdollisuuksia. Sen lisäksi ohjaava analytiikka nähtiin nousevana trendinä, mutta se vaatii edistyneitä analytiikkajärjestelmiä sekä henkilöstön osaamista. Luvun myötä selvisi, miksi data-analytiikasta on tullut entistä tärkeämpi osa yritysten hankintojen kehittämistä. Sen myötä laaja kuluseuranta sekä monipuolisten enustemallien hyödyntäminen on mahdollista.

Tutkimuksen neljäs luku sisälsi skenaarioihin liittyvän teoreettisen katsauksen. Luvun keskiöön nousi skenaario käsitteenä sekä skenaarioanalyysin merkitys suunnittelumenetelmänä. Aiemmissä tutkimuksissa voitiin havaita, että skenaarioiden luonnissa data voi olla mitä vain. Erilaisia menetelmiä on lukuisia, joista trendivaikutteista TIA-menetelmää

hyödynnettiin tässä tutkimuksessa. Luvussa todettiin, että skenaario mielletään usein virheellisesti ennustamiseksi, vaikka ne ovat mahdollisia tulevaisuuskuvia. Aiemmissä tutkimuksissa havaittiin, että skenaarioanalyysin avulla yritys voi valmistautua tulevaisuuteen, eikä pelkästään reagoida jo tapahtuneisiin muutoksiin. Ennen tutkimuksen empiiristä osuutta viidennessä luvussa esitettiin vielä case-yrityksen epäsuoria hankintoja, autoalan toimialaa sekä vuoden 2024 markkinaa.

Tutkimuksen teoriaosuuden avulla luotiin pohja tutkimuskysymyksille, joita testattiin tutkimuksen kuudennessa luvussa. Case-yritykselle luotiin PESTEL-analyysi, jonka avulla tunnistettiin case-yrityksen ulkoisia toimintaympäristötekijöitä. PESTEL-analyysin havainnot toimivat pohjana skenaarioiden taustaolettamuksille ja ennakoivalle mallinnukselle. TIA-menetelmää hyödyntämällä tunnistettiin, miten historiallista dataa ja tunnistettuja trendejä yhdistämällä voitiin luoda ennakoiva laskentamalli epäsuorille hankinnoille. Neljän skenaarion avulla arvioitiin epäsuorien hankintojen mahdollisia kehityspolkuja vuoteen 2034 saakka.

7.2 Johtopäätökset

Tutkimuksen alussa esitettiin kolme tutkimuskysymystä, jotka ohjasivat tutkimuksen teoria- ja empiriaosan rakentamista. Tämän tutkimuksen ollessa päätöksentekometodologinen, ei suoranaista vertailua teorian ja tutkimustulosten välillä voida suorittaa, toisin kuin tutkimuksissa, joissa tutkimusmenetelmänä on esimerkiksi laadullinen kyselytutkimus tai lineaarinen regressioanalyysi. Alla esitettynä tutkimuksen alussa luodut tutkimuskysymykset:

1. Miten data-analytiikkaa voidaan soveltaa hankintojen tutkinnassa?
2. Mitkä ovat tärkeimmät ulkoiset tekijät, jotka vaikuttavat case-yrityksen epäsuorien hankintojen kehitykseen vuosina 2025–2034?
3. Voiko case-yritys saada skenaarioanalyysillä tukea strategiseen päätöksentekoon sekä epäsuorien hankintojen ennakkointiin?

Ensimmäisen tutkimuskysymyksen kohdalla data-analytiikan hyödyntämisellä hankintojen tutkinnassa nähtiin selkeä hyöty. Epäsuorien hankintoihin liittyvässä kirjallisuudessa mainittiin kulujen nykytilan hahmottamisen tärkeydestä ennen analyysin tekoa. Hankinnat olisi hyvä kategorisoida, ja jokaisen hankittavan tuotteen tai palvelun täytyisi kuulua johonkin hankintastrategiaan. Case-yrityksen eikä minkään muunkaan yrityksen analytiikkatyökalut voi analysoida dataa, jos hankintoja ei ole huolellisesti kategorisoitu ja dataa jäsennelty. Kirjallisuuden pohjalta voidaan todeta, että case-yrityksen täytyy kategorisoida hankintansa, ennen kuin toimittajien laskuilta ja sopimuksilta aloitetaan kustannussäästöjen tutkiminen. Datan laadun on oltava erinomaista, sillä dataprosessin ollessa heikko, on myös data-analytiikkaa haastavaa hyödyntää.

Tutkimustulokset osoittivat data-analytiikan avulla saavutettavan hyötyjä hankintadatan analysoinnista. Se vaatii kuitenkin virheetöntä hankintadatan laatua. Esitetyistä data-analytiikan tasoista ennakoivan ja ohjaavan analytiikan hyödyt konkretisoituvat silloin, kun yrityksessä on käytössä laadukkaat analytiikkajärjestelmät ja kyky hyödyntää tekoälyä ennustemalleissa, kuten Bhaskaranin (2025) tutkimus Alibaban tekoälymallista osoitti. Aiemmat tutkimukset data-analytiikan hyödyntämisestä kustannussäästöissä osoittivat, että erilaisilla analyttisillä ratkaisuilla voidaan havaita merkittäviäkin kustannussäästöjä. Tässä tutkimuksessa luotu laskentamalli osoittaa myös data-analytiikan hyödyn. Ennakoivan analytiikan avulla rakennettu laskentamalli on käytännön esimerkki, miten data-analytiikalla saadaan pitkän aikavälin skenaarioita sekä tukea strategiseen suunnitteluun.

Toisella tutkimuskysymyksellä haettiin vastausta case-yrityksen ulkoisten tekijöiden vaikutuksiin epäsuorien hankintojen kehityksessä. Jotta case-yrityksen epäsuorien hankintojen kehitys voitiin ymmärtää, nähtiin tutkimuksen kannalta tarpeelliseksi analysoida kokonaisvaltaisesti case-yrityksen liiketoimintaympäristöä PESTEL-analyysin avulla. Julkisten tulevaisuus selvitysten pohjalta rakennettu analyysi sisälsi poliittisten, ekonomisten, sosiaalisten, teknologisten, ekologisten ja lainsäädännöllisten tekijöiden ilmiöitä. PESTEL-analyysin tarkoituksena oli saada luotettava lähtökohta ennakoivalle

mallintamiselle. Vaikka tuleviin muutoksiin ja trendeihin ei pystyisi vaikuttamaan, on ne kuitenkin hyvä tiedostaa ja huomioida.

PESTEL-analyysin tuloksista voidaan nostaa esille ekologisten ja poliittisten tekijöiden suuri merkitys case-yrityksen toiminnassa. Suomen valtio pyrkii olemaan hiilineutraali vuonna 2035, minkä saavuttamiseksi liikenteestä aiheutuvat päästöt on minimoitava. Myös EU:n asettama kestävyysraportointistandardi osoittaa, että yritysten on keskityttävä tulevaisuudessa entistä enemmän kestävään kehitykseen liiketoiminnassaan. Teknologisista tekijöistä keskeisiä kehitystoimia nähdään tapahtuvan tekoälyn ja automaation yleistyessä yritysten ja myös case-yrityksen liiketoiminnassa. Se vaatii kuitenkin case-yritykseltä investointeja sekä järjestelmiin että työntekijöiden osaamiseen. Kuitenkin tässä tutkimuksessa autoalan sähköistyminen ja liikenteen päästövähennystavoitteet nähtiin kaikista merkittävimpinä liiketoimintaa ohjaavina ajureina seuraavan kymmenen vuoden aikana vuoteen 2034 saakka.

Tutkimuksen kolmannella tutkimuskysymyksellä haettiin vastausta kysymykseen, saako case-yritys luodulla skenaarioanalyysillä tukea strategiseen päätöksentekoon ja epäsuorien hankintojen ennakkointiin. Tutkimustulosten perusteella voidaan vastata, että kyllä saa. Skenaarioanalyysin tarkoituksena on luoda useampia mahdollisia tulevaisuuskuvia, eikä antaa yksittäistä niin sanotusti ”oikeaa” vastausta tulevaisuuden tilasta. Tutkimuksessa luotiin neljä skenaariota epäsuorien hankintojen kehityksestä vuosina 2025–2034, jotka havainnollistivat, miten eri tilanteissa tietyt ulkoiset tekijät korostuvat epäsuorissa hankinnoissa. Case-yrityksen osalta epäsuorien hankintojen riskienhallinnan voidaan olettaa paranevan, kun eri ulkoisten tekijöiden vaikutuksia tunnistettiin.

Tutkimuksessa skenaarioanalyysin muodostumiseksi luotu laskentamalli osoittaa sen olevan sopiva työkalu, kun ennakoidaan pitkän aikavälin kehitystä. Luotu skenaarioanalyysi antaa case-yrityksen johtoryhmälle mahdollisuuden ennakoida epäsuoria hankintoja, kun ulkoiset tekijät huomioidaan. Kuten aiemmin on mainittu, niin sisäisessä versiossa analyysiin sisältyy myös epäsuorien hankintojen kuluerien mahdolliset

muutostekijät, minkä myötä pitkän aikavälin ennakkoinnista voidaan saada vielä tarkempi, kun sekä ulkoiset että sisäiset tekijät huomioidaan.

Yhteenvetona voidaan todeta, että case-yrityksen strateginen ote epäsuoriin hankintoihin – niin kehittämisen kuin ennakkoinnin suhteen – on merkittävä tapa parantaa kilpailukykyä. Data-analytiikkaa hyödyntäessä kustannussäästöjen havainnoinnissa case-yrityksen tulee varmistaa datan hyvä laatu, analyytikkojen osaamisen korkea taso sekä järjestelmien kehittyneisyys. Syvällisellä hankinta-analyysillä case-yritys voi saada optimoitua hankintojaan lyhyellä aikavälillä, kun taas mallinnetussa skenaarioanalyysissä korostuu pitkän aikavälin strateginen ennakkointi. Tällä hetkellä case-yrityksessä ei ole tulevaisuusanalyysijä tekeviä työntekijöitä, minkä vuoksi sen on todennäköisesti joko muutettava jo yrityksessä työskentelevien työntekijöiden työnkuvaa tai rekrytoitava tulevaisuusosaamisen omaavaa henkilöstöä, mikäli case-yritys haluaa säännöllisesti luoda ennakovia raportteja toiminnastaan.

7.3 Jatkotutkimusehdotukset

Tutkimukselle on nähtävissä lukuisia jatkotutkimuskohteita. Tutkimuksessa tutkittiin useampaa aihetta, ja varsinkin epäsuorien hankintojen käsite on varsin laaja. Yksi mielenkiintoinen tutkimusaihe voisi olla case-yrityksen sijaan jonkin tietyn toimialan yritysten epäsuorien hankintojen ennakkointi. Esimerkiksi yhdysvaltalaisen autoteollisuuden yritysten vertailu kiinalaisiin autoteollisuuden yrityksiin olisi ajankohtainen ja mielenkiintoinen aihe, sillä tällä hetkellä suurimmat sähköautojen valmistajat sijaitsevat Yhdysvalloissa ja Kiinassa. Vertailussa voisi olla yhdysvaltalaisyhtiö Tesla ja kiinalaisyhtiö BYD. Tässä tutkimuksessa hyödynnetyn PESTEL-analyysin sijaan Teslalle ja BYD:lle voitaisiin luoda SWOT-analyysit, ja epäsuorien hankintojen sijaan ennakoida esimerkiksi liikevaihdon kehitystä eri skenaarioissa.

Tutkimuksessa luodut skenaariot rajattiin vuositasolle. Rakennettua laskentamallia voisi muuttaa vuositarkastelun sijaan kuukausitasolle, mikä voisi mahdollistaa laskentamallin

käyttämisen myös budjetoinnin apuna. Mallia voisi kehittää siten, että mahdollisten ulkoisten tekijöiden muutoksia kustannuskehitykseen voisi arvioida myös lyhyemmällä ajanjaksolla vuositarkastelun sijaan. Laskentamallin mukaista ennakoivaa laskentaa hyödyntämällä kuukausitasolle, voisi epäsuorien hankintojen budjetointiprosessiin olla mahdollista ottaa paremmin huomioon myös ulkoisen toimintaympäristön muutokset.

Tutkimuksessa luotujen skenaarioiden kehitykset esitettiin informatiivisina kuvioina. Sisäisessä versiossa aiemmin mainitut neljä epäsuorien hankintojen kuluerää esitetään jokinainen itsenäisenä eränä. Tässä tutkimuksessa epäsuorat hankinnat jaettiin neljään erään, joista karkeasti jaoteltuna operatiivisia kuluja voidaan pitää muuttuvina kustannuksina ja muita kolmea erää kiinteinä kustannuksina. Mallinnusta voisi kehittää siten, että vertailuun otettaisiin epäsuorien hankintojen osuus liikevaihdosta. Jos ajatellaan case-yrityksen liikevaihdon kasvavan seuraavan kolmen vuoden aikana esimerkiksi 30 prosenttia, niin hyvin todennäköisesti kyseisellä ajanjaksolla muuttuvat kulut kasvavat liikevaihdon kasvun myötä enemmän kuin kiinteät kulut. Täten kehityksen esittämisestä saisi informatiivisemmän, kun lyhyellä ajanjaksolla muuttuvien kulujen määrä voi muuttua huomattavasti enemmän kiinteihin kuluihin verrattuna.

Tämän tutkimuksen skenaariotyöskentelyssä hyödynnettiin ennakoivan mallinnuksen tukena TIA-menetelmää sekä PESTEL-analyysiä. Case-yritykselle sisäisesti palautettava versio todennäköisesti luo keskustelua ja ideointia mahdollisista jatkokehityksaiheista. Tämä tutkimus voi esimerkiksi luoda kehityskohteen jollekin toiselle ennakoivalle aiheelle epäsuorien hankintojen sijaan. Teoriaosuudessa todettiin, että skenaariotyöskentelyyn on mahdollista liittää useita eri menetelmiä, joten hyvin monipuolisten aiheiden tutkiminen case-yrityksen sisällä on mahdollista skenaariotyöskentelyn joustavuuden myötä. Yksi mielenkiintoinen ennakoitava kohde voisi olla case-yrityksen sähköajoneuvojen osuus varastosta eri skenaarioissa.

Tässä tutkimuksessa mallinnetut skenaariot vastaavat pääosin kysymykseen: ”Mitä tulevaisuudessa tapahtuu?”. Liikesalaisuuksista johtuen tämän tutkimuksen ulkopuolelle

jätetään sisäisesti case-yrityksessä tehtävä jatkoanalyysi, jonka tarkoituksena on vastata kysymykseen: ”Miten täytyisi toimia?”. Sisäisesti suoritettavassa arvioinnissa case-yrityksen tulisi pohtia, kuinka valmistautua ja toimia, jos laaditut skenaariot toteutuvat. Skenaarioiden tarkoituksena ei kuitenkaan ole täydellisen tulevaisuuden ennustaminen, vaan vaihtoehtoisten tulevaisuuskuvien luominen. On siis hyvä muistaa skenaarioita arvioitaessa niiden sisältävän epävarmuutta, eikä missään laskentamallissa voida huomioida kaikkia mahdollisia tekijöitä.

Lähteet

- Agami, N. M. E., Omran, A. M. A., Saleh, M. M. & El-Shishiny, H. E. E. (2008). An enhanced approach for Trend Impact Analysis. *Technological forecasting & social change*. Vol. 75 No. 9 s. 1439–1450. <https://doi.org/10.1016/j.techfore.2008.03.006>
- Aligica, P. (2004). The challenge of the future and the institutionalization of interdisciplinarity: notes on Herman Kahn's legacy. *Futures: the journal of policy, planning and futures studies*. Vol. 36 No. 1 s. 67–83. [https://doi.org/10.1016/S0016-3287\(03\)00136-8](https://doi.org/10.1016/S0016-3287(03)00136-8)
- Aljohani, A. (2023). Predictive Analytics and Machine Learning for Real-Time Supply Chain Risk Mitigation and Agility. *Sustainability*, 15(20), 15088. <https://doi.org/10.3390/su152015088>
- Appelbaum, D., Kogan, A., Vasarhelyi, M., & Yan, Z. (2017). Impact of business analytics and enterprise systems on managerial accounting. *International journal of accounting information systems*, 25, 29–44. <https://doi.org/10.1016/j.acinf.2017.03.003>
- Autoalan Keskusliitto. (2024). Autoalan käyttövoimaennusteet. Noudettu 9.2.2025 osoitteesta https://www.aut.fi/files/2861/Kayttovoimaennusteet_2024_2205.pdf
- Autoalan Tiedotuskeskus. (2024). Hallitus jatkaa täyssähköisten työsuhdeautojen verokannustetta. Noudettu 28.1.2025 osoitteesta https://www.aut.fi/ajankoh-taista/tiedotteet/hallitus_jatkaa_tayssahkoisten_tyosuhdeautojen_verokannustetta.3556.news
- Autoalan Tiedotuskeskus. (2025). Automarkkinoiden vuosikatsaus. Noudettu 28.1.2025 osoitteesta https://www.aut.fi/files/2931/Vuosikatsaus_media.pdf
- Bacon, E. (2012). Writing Russia's Future: Paradigms, Drivers, and Scenarios. *Europe-Asia studies*. Vol. 64 No. 7 s. 1165–1189. <https://doi.org/10.1080/09668136.2012.698046>
- Balarezo, J. & Nielsen, B. B. (2017). Scenario planning as organizational intervention: An integrative framework and future research directions. *International journal of commerce and management*. Vol. 27 No. 1 s. 2–52. <https://doi.org/10.1108/RIBS-09-2016-0049>

- Banuls, V. A. & Salmeron, J. L. (2007). A Scenario-Based Assessment Model—SBAM. *Technological forecasting & social change*. Vol. 74 No. 6 s. 750–762. <https://doi.org/10.1016/j.techfore.2006.05.015>
- Beck, T. E. & Plowman, D. A. (2009). Experiencing Rare and Unusual Events Richly: The Role of Middle Managers in Animating and Guiding Organizational Interpretation. *Organization science (Providence, R.I.)*. Vol. 20 No. 5 s. 909–924. <https://doi.org/10.1287/orsc.1090.0451>
- Bhaskaran, S. V. (2025). EnterpriseAI: A Transformer-Based Framework for Cost Optimization and Process Enhancement in Enterprise Systems. *Computers (Basel)*, 14(3), 106. <https://doi.org/10.3390/computers14030106>
- Bokrantz, J., Skoogh, A., Berlin, C., & Stahre, J. (2017). Maintenance in digitalised manufacturing: Delphi-based scenarios for 2030. *International journal of production economics*. Vol. 191 s. 154–169. <https://doi.org/10.1016/j.ijpe.2017.06.010>
- Bonfim, D., Custódio, C., & Raposo, C. (2023). Supporting small firms through recessions and recoveries. *Journal of financial economics*, 147(3), 658–688. <https://doi.org/10.1016/j.jfineco.2023.01.004>
- Bradfield, R., Wright, G., Burt, G., Cairns, G. & Van Der Heijden, K. (2005). The origins and evolution of scenario techniques in long range business planning. *Futures: the journal of policy, planning and futures studies*. Vol. 37 No 8 s. 795–812. <https://doi-org.proxy.uwasa.fi/10.1016/j.futures.2005.01.003>
- Bresman, H. (2013). Changing routines: A process model of vicarious group learning in pharmaceutical R & D. *Academy of Management journal*. Vol. 56 No 1 s. 35–61. <https://doi.org/10.5465/amj.2010.0725>
- Bulusu, L., & Abellera, R. (2021). AI meets BI: Artificial intelligence and business intelligence. *CRC Press*.
- Börjeson, L., Höjer, M., Dreborg, K., Ekvall, T. & Finnveden, G. (2006). Scenario types and techniques: Towards a user's guide. *Futures: the journal of policy, planning and futures studies*. Vol. 38 No. 7 s. 723–739. <https://doi.org/10.1016/j.futures.2005.12.002>

- Cairns, G., Śliwa, M., & Wright, G. (2010). Problematizing international business futures through a 'critical scenario method'. *Futures: the journal of policy, planning and futures studies*. Vol. 42 No. 9 s. 971–979. <https://doi.org/10.1016/j.futures.2010.08.016>
- Cairns, G., Goodwin, P. & Wright, G. (2016). A decision-analysis-based framework for analysing stakeholder behaviour in scenario planning. *European journal of operational research*. Vol. 249 No. 3 s. 1050–1062. <https://doi.org/10.1016/j.ejor.2015.07.033>
- Chermack, T. J., Bodwell, W. & Glick, M. (2010). Two Strategies for Leveraging Teams Toward Organizational Effectiveness: Scenario Planning and Organizational Ambidexterity. *Advances in developing human resources*. Vol. 12 No.1 s. 137–156. <https://doi.org/10.1177/1523422310365669>
- Chermack, T. J. & Nimon, K. (2013). Drivers and outcomes of scenario planning: A canonical correlation analysis. *European journal of training and development*. Vol. 37 No 9 s. 811–834. <https://doi.org/10.1108/EJTD-03-2013-0030>
- Cirani, S., Ferrari, G., Picone, M. & Veltri, L. (2018). Internet of Things: Architectures, Protocols and Standards. *John Wiley & Sons, Incorporated*.
- Culot, G., Orzes, G., Sartor, M. & Nassimbeni, G. (2020). The future of manufacturing: A Delphi-based scenario analysis on Industry 4.0. *Technological forecasting & social change*. Vol. 157. <https://doi.org/10.1016/j.techfore.2020.120092>
- Davenport, T. H. (2014). Big data at work: Dispelling the myths, uncovering the opportunities. *Harvard Business Review Press*.
- Davenport, T. H., Harris, J. G., Abney, D., & Abney, D. (2017). Competing on analytics: The new science of winning (Updated, with a new introduction.). *Harvard Business Review Press*.
- Deng, Y., Zhang, X., Wang, T., Wang, L., Zhang, Y., Wang, X., . . . Peng, X. (2023). Alibaba Realizes Millions in Cost Savings Through Integrated Demand Forecasting, Inventory Management, Price Optimization, and Product Recommendations. *INFORMS journal on applied analytics*, 53(1), 32-46. <https://doi.org/10.1287/inte.2022.1145>

- Eloranta, J., Uusitalo, R., Gaudeamus oy, Eloranta, J., & Uusitalo, R. (2024). Ankarat ajat: Suomalaisten talouskriisien pitkä historia. *Gaudeamus*.
- European Commission. (2023). Fit for 55: EU reaches new milestone to make all new cars and vans zero-emission from 2035. *Directorate-General for Climate Action*. Noudettu 12.2.2025 osoitteesta https://climate.ec.europa.eu/news-your-voice/news/fit-55-eu-reaches-new-milestone-make-all-new-cars-and-vans-zero-emission-2035-2023-03-28_en
- Georgino, M., Alcantara, R. L. C., & Albuquerque, A. A. d. (2021). Procurement process and financial performance: A systematic literature review. *GEPROS : Gestão da Produção, Operações e Sistemas*, 16(3), 69. <https://doi.org/10.15675/gepros.v16i3.2770>
- Ghasemian, S., Faridzad, A., Abbaszadeh, P., Taklif, A., Ghasemi, A. & Hafezi, R. (2020). An overview of global energy scenarios by 2040: Identifying the driving forces using cross-impact analysis method. *International journal of environmental science and technology (Tehran)*. <https://doi.org/10.1007/s13762-020-02738-5>
- Giesecke, J., Cawthorne, J. & Pearson, D. (2015). Navigating the Future with Scenario Planning: A Guidebook for Librarians. *Association of College & Research Libraries*.
- Godet, M. (2000). The Art of Scenarios and Strategic Planning: Tools and Pitfalls. *Technological forecasting & social change*. Vol. 65 No. 1 s. 3–22. [https://doi.org/10.1016/S0040-1625\(99\)00120-1](https://doi.org/10.1016/S0040-1625(99)00120-1)
- Goodspeed, R., Admassu, K., Bahrami, V., Bills, T., Egelhaaf, J., Gallagher, K., Lynch, J., Masoud, N., Shurn, T., Sun, P., Wang, Y. & Wolf, C. (2023). Improving transit in small cities through collaborative and data-driven scenario planning. *Case studies on transport policy*. Vol. 11. <https://doi.org/10.1016/j.cstp.2023.100957>
- Gupta, S., Drave, V. A., Dwivedi, Y. K., Baabdullah, A. M. & Ismagilova, E. (2020). Achieving superior organizational performance via big data predictive analytics: A dynamic capability view. *Industrial marketing management*. Vol. 90 s. 581–592. <https://doi.org/10.1016/j.indmarman.2019.11.009>

- Hammoud, M. & Nash, D. (2014). What corporations do with foresight. *European journal of futures research*. Vol. 2 No. 1 s. 1–20. <https://doi.org/10.1007/s40309-014-0042-9>
- Harris, G. (2014). Four blind alleys of scenario analysis. *Strategy & leadership*. Vol. 42 No. 6 s. 37–41. <https://doi.org/10.1108/SL-09-2014-0068>
- Hausmann, K. (2023). How to Improve The Bottom Line with Mandated Spending. *Credit Control*, 44(3/4), 26–29.
- Heinonen, S. & Lauttamäki, V. (2012). Backcasting scenarios for Finland 2050 of low emissions. *Foresight (Cambridge)*. Vol. 14 No. 4 s. 304–315. <https://doi.org/10.1108/14636681211256099>
- Holman, J. O., & Hacherl, A. (2023). Teaching Monte Carlo Simulation with Python. *Journal of Statistics and Data Science Education*, 31(1), 33-44. <https://doi.org/10.1080/26939169.2022.2111008>
- Hoover Green, A. & Cohen, D. K. (2021). Centering Human Subjects: The Ethics of “Desk Research” on Political Violence. *Journal of global security studies*. Vol. 6 No. 2. <https://doi.org/10.1093/jogss/ogaa029>
- Hovi, A., Hervonen, H. & Koistinen, H. (2009). Tietovarastot ja business intelligence. *Docendo*.
- Højland, J. & Rohrbeck, R. (2018). The role of corporate foresight in exploring new markets—evidence from 3 case studies in the BOP markets. *Technology analysis & strategic management*. Vol. 30 No. 6 s. 734–746. <https://doi.org.proxy.uwasa.fi/10.1080/09537325.2017.1337887>
- Iloranta, K., Pajunen-Muhonen, H., & Tietosanoma. (2018). Hankintojen johtaminen: Os-tamisesta toimittajamarkkinoiden hallintaan (Viides, tarkistettu laitos.). *Tietosa-noma*.
- Isson, J. & Hwang, M. (2018). Unstructured Data Analytics: How to improve customer acquisition, customer retention, and fraud detection and prevention. *John Wiley & Sons, Incorporated*.
- KaaraTV Podcast. (2023). Minkälainen on autokaupan tulevaisuus, Autoalan keskusliiton toimitusjohtaja Tero Lausala? *Spotify*. Noudettu 12.1.2025 osoitteesta

https://open.spotify.com/episode/0j1fi0aRnuqOT-WEwC91Cq3?si=MGN4_47DSkmB_m7RKBc9rQ

- Kaitila, V. (2021). Skenaariolaskelmia kotitalouksien liikennepäästöjen kehityksestä. *ETLA Muistio 99*. Noudettu 24.2.2025 osoitteesta <https://pub.etla.fi/ETLA-Muistio-Brief-99.pdf>
- Kamensky, M. (2014). Strateginen johtaminen: Menestyksen timantti (4., tarkistettu painos.). *Talentum*.
- Kasanen, E., Lukka, K., & Siitonen, A. (1993). The constructive approach in management accounting research. *Journal of management accounting research*, 5, 243.
- Kokkinen, A., Jalasjoki, P. & Obstbaum, M. (2025). Työikäisen väestön supistuminen ja heikko tuottavuus painavat Suomen pitkän ajan kasvunäkymää. *Suomen Pankki*. Noudettu 21.2.2025 osoitteesta <https://www.eurojatalous.fi/fi/2025/artikkelit/tyoikaisen-vaeston-supistuminen-ja-heikko-tuottavuus-painavat-suomen-pitkan-ajan-kasvunakymaa/>
- KPMG. (2024). Future of procurement. Noudettu 12.2.2025 osoitteesta <https://assets.kpmg.com/content/dam/kpmg/xx/pdf/2024/04/future-of-procurement-2024.pdf>
- Kuvaas, B. (2002). An Exploration of Two Competing Perspectives on Informational Contexts in Top Management Strategic Issue Interpretation. *Journal of management studies*. Vol. 39 No. 7 s. 977–1001. <https://doi.org/10.1111/1467-6486.00320>
- Labro, E., & Tuomela, T. (2003). On bringing more action into management accounting research: Process considerations based on two constructive case studies. *The European accounting review*, 12(3), 409–442. <https://doi.org/10.1080/0963818032000083559>
- Landeta, J. (2006). Current validity of the Delphi method in social sciences. *Technological forecasting & social change*. Vol. 73 No. 5 s. 467–482. <https://doi.org/10.1016/j.techfore.2005.09.002>
- Lang, T., Malinen, A., Kyyrö, M. & Öörni, R. (2021). Kiihdytyskaistalla tulevaisuuden osamiseen. *Metropolia Ammattikorkeakoulu*. Noudettu 30.1.2025 osoitteesta

https://publications.vtt.fi/julkaisut/muut/2022/Kiihdytyskaistalla_tulevaisuuden_osaamiseen.pdf

- Lausala, T. (2024). Tarvitsemme puhtaampaa ja turvallisempaa liikennettä. *Kaupan Liitto*. Noudettu 24.1.2025 osoitteesta <https://kauppa.fi/uutishuone/2024/12/11/tarvitsemme-puhtaampaa-ja-turvallisempaa-liikennetta/>
- Leshcheva, I. & Begler, A. (2022). A method of semi-automated ontology population from multiple semi-structured data sources. *Journal of information science*. Vol.48 s. 223–236. <https://doi-org.proxy.uwasa.fi/10.1177/0165551520950243>
- Liikenne- ja viestintäministeriö. (2021). Fossiilittoman liikenteen tiekartta : Valtioneuvoston periaatepäätös kotimaan liikenteen kasvihuonepäästöjen vähentämisestä. *Liikenne- ja viestintäministeriön julkaisuja 2021:15*. <http://urn.fi/URN:ISBN:978-952-243-588-0>
- Liikenne- ja viestintäministeriö. (2024). Liikenne- ja viestintäministeriön vastuullisuusraportti 2023. *Liikenne- ja viestintäministeriön julkaisuja 2024:8*. <http://urn.fi/URN:ISBN:978-952-243-739-6>
- Listenmaa, J., & Alma Talent. (2023). Laita tieto töihin: Tiedolla johtamisen käsikirja. *Alma Talent*.
- Liu, Y., Gupta, H., Springer, E. & Wagener, T. (2008). Linking science with environmental decision making: Experiences from an integrated modeling approach to supporting sustainable water resources management. *Environmental modelling & software: with environment data news*. Vol. 23 No. 7 s. 846–858. <https://doi.org/10.1016/j.envsoft.2007.10.007>
- Lukka, K. (2005). Approaches to case research in management accounting: the nature of empirical intervention and theory linkage. *Accounting in Scandinavia – The northern lights*.
- Lukka, K., & Wouters, M. (2022). Towards interventionist research with theoretical ambition. *Management accounting research*, 55, 100783. <https://doi.org/10.1016/j.mar.2022.100783>

- Luo, Q., Zhai, C., Sun, D., Chen, W. & Li, Q. (2019). Interpolation and extrapolation with the CALPHAD method. *Journal of materials science & technology*. Vol. 35 No. 9 s. 2115–2120. <https://doi.org/10.1016/j.jmst.2019.05.016>
- Mahmoud, M., Liu, Y., Hartmann, H., Stewart, S., Wagener, T., Semmens, D., Stewart, R., Gupta, H., Dominguez, D., Dominguez, F., Hulse, D., Letcher, R., Rashleigh, B., Smith, C., Street, R., Ticehurst, J., Twery, M., van Delden, H., Waldick, R., White, D. & Winter L. (2009). A formal framework for scenario development in support of environmental decision-making. *Environmental modelling & software: with environment data news*. Vol. 24 No. 7 s. 798–808. <https://doi.org/10.1016/j.envsoft.2008.11.010>
- Mandl, C., & Minner, S. (2023). Data-Driven Optimization for Commodity Procurement Under Price Uncertainty. *Manufacturing & service operations management*, 25(2), 371–390. <https://doi.org/10.1287/msom.2020.0890>
- Mannermaa, M. (1999). Tulevaisuuden hallinta: skenaariot strategiatyöskentelyssä. *WSOY*.
- Mannermaa, M., & Werner Söderström osakeyhtiö. (2004). Heikoista signaaleista vahva tulevaisuus. *WSOY*.
- Marr, B. (2015). Big Data. *John Wiley & Sons, Incorporated*.
- Meyerowitz, D., Lew, C. & Svensson, G. (2018). Scenario-planning in strategic decision-making: requirements, benefits and inhibitors. *Foresight*. Vol. 20 No. 6 s. 602–621. <https://doi-org.proxy.uwasa.fi/10.1108/FS-04-2018-0036>
- Millington, D. (2021). Direct vs. Indirect Spend. *American Fastener Journal*, 37(5), 8.
- Miller, K. D. & Waller, H. (2003). Scenarios, Real Options and Integrated Risk Management. *Long range planning*. Vol. 36 No. 1 s. 93–107. [https://doi.org/10.1016/S0024-6301\(02\)00205-4](https://doi.org/10.1016/S0024-6301(02)00205-4)
- Millett, S. M. (2003). The future of scenarios: Challenges and opportunities. *Strategy & leadership*. Vol. 31 No. 2 s. 16–24. <https://doi.org/10.1108/10878570310698089>
- Mitronen, L., Raikaslehto, T., & Alma Talent. (2019). Voittajan strategia: Lyhytjänteisyydestä kestävään menestykseen. *Alma Talent*.

- Mohd Selamat, S. A., Prakoonwit, S., Sahandi, R., Khan, W., & Ramachandran, M. (2018). Big data analytics—A review of data-mining models for small and medium enterprises in the transportation sector. *Wiley interdisciplinary reviews. Data mining and knowledge discovery*, 8(3), e1238-n/a. <https://doi.org/10.1002/widm.1238>
- Nair, A., Jayaram, J. and Das, A. (2015). Strategic purchasing participation, supplier selection, supplier evaluation and purchasing performance. *International Journal of Production Research*. Vol. 53 No. 20 s. 6263–6278. <https://doi.org/10.1080/00207543.2015.1047983>
- Nowack, M., Endrikat, J. & Guenther, E. (2011). Review of Delphi-based scenario studies: Quality and design considerations. *Technological forecasting & social change*. Vol. 78 No. 9 s. 1603–1615. <https://doi.org/10.1016/j.techfore.2011.03.006>
- Oliver, J. J. & Parrett, E. (2018). Managing future uncertainty: Reevaluating the role of scenario planning. *Business horizons*. Vol. 61 No. 2 s. 339–352. <https://doi-org.proxy.uwasa.fi/10.1016/j.bushor.2017.11.013>
- OpenAI. (2023). ChatGPT. Noudettu 4.12.2024 osoitteesta <https://chatgpt.com/>
- Parenté, F. J., Anderson, J. K., Myers, P. & O'brien, T. (1984). An examination of factors contributing to delphi accuracy. *Journal of forecasting*. Vol. 3 No. 2 s. 173–182. <https://doi.org/10.1002/for.3980030205>
- Paulraj, A., Chen, I. J., & Blome, C. (2017). Motives and Performance Outcomes of Sustainable Supply Chain Management Practices: A Multi-theoretical Perspective. *Journal of business ethics*, 145(2), 239–258. <https://doi.org/10.1007/s10551-015-2857-0>
- Payne, J., Dorn, W. R., Pastore, D., & Ulrich, J. (2021). Managing Indirect Spend: Enhancing Profitability Through Strategic Sourcing. *John Wiley & Sons, Inc.*
- Peter, M. & Jarratt, D. (2015). The practice of foresight in long-term planning. *Technological forecasting & social change*. Vol. 101 s. 49–61. <https://doi.org/10.1016/j.techfore.2013.12.004>
- Picatoste, J., Pérez-Ortiz, L., Ruesga-Benito, S. M. & Novo-Corti, I. (2018). Smart cities for wellbeing: Youth employment and their skills on computers. *Journal of Science*

- and Technology Policy Management*. Vol. 9 No. 2 s. 227–241.
<https://doi.org/10.1108/JSTPM-04-2017-0014>
- Pop, A. & Grigoraş, R. (2021). Towards a bifurcated future in the US-China relationship: What is in it for the EU? *Futures: the journal of policy, planning and futures studies*. Vol. 125. <https://doi.org/10.1016/j.futures.2020.102634>
- Ray, M., Rai, A., Singh, K., V., R., & Kumar, A. (2017). Technology forecasting using time series intervention based trend impact analysis for wheat yield scenario in India. *Technological forecasting & social change*. Vol. 118 s. 128–133.
<https://doi.org/10.1016/j.techfore.2017.02.012>
- Reinecke, N., Spiller, P., & Ungerman, D. (2007). The talent factor in purchasing. *The McKinsey quarterly*, 1, 6.
- Rocchio, B. J. (2016). Achieving Cost Reduction Through Data Analytics. *AORN journal*, 104(4), 320-325. <https://doi.org/10.1016/j.aorn.2016.07.010>
- Rotmans, J., van Asselt, M., Anastasi, C., Greeuw, S., Mellors, J., Peters, S., Rothman, D. & Rijkens, N. (2000). Visions for a sustainable Europe. *Futures: the journal of policy, planning and futures studies*. Vol. 32 No. 9 s. 809–831.
[https://doi.org/10.1016/S0016-3287\(00\)00033-1](https://doi.org/10.1016/S0016-3287(00)00033-1)
- Sadler-Smith, E. (2008). The Role of Intuition in Collective Learning and the Development of Shared Meaning. *Advances in developing human resources*. Vol. 10 No. 4 s. 494–508. <https://doi.org/10.1177/1523422308320065>
- Salo, I. (2013). Big Data: Tiedon vallankumous. *Docendo Oy*.
- Sapio, B. (1995). SEARCH (Scenario evaluation and analysis through repeated cross impact handling): A new method for scenario analysis with an application to the Videotel service in Italy. *International journal of forecasting*. Vol. 11 No. 1 s. 113–131. [https://doi.org/10.1016/0169-2070\(94\)02002-7](https://doi.org/10.1016/0169-2070(94)02002-7)
- Sargut, G. & McGrath, R. (2011). Learning to live with complexity. *Harvard business review*. Vol. 89, No. 9, 68–136. Noudettu 11.1.2025 osoitteesta <https://research-ebSCO-com.proxy.uwasa.fi/c/slwlh3/viewer/pdf/kwsdxtsnjz>
- Sawik, T. (2011). Scheduling in Supply Chains Using Mixed Integer Programming. *John Wiley & Sons, Incorporated*.

- Schoemaker, P. (1995). SCENARIO PLANNING - A TOOL FOR STRATEGIC THINKING. *Sloan management review*. Vol. 36 No. 2 s. 25–40. Noudettu 25.1.2025 osoitteesta: <https://www.proquest.com/docview/224969642/F9E27DAB07AA4E61PQ/13?accountid=14797>
- Schweizer, J., Poliziani, C., Rupi, F., Morgano, D. & Magi, M. (2021). Building a large-scale micro-simulation transport scenario using big data. *ISPRS international journal of geo-information*. Vol. 10 No. 3. <https://doi.org/10.3390/ijgi10030165>
- Shollo, A. & Galliers, R. D. (2016). Towards an understanding of the role of business intelligence systems in organisational knowing. *Information systems journal (Oxford, England)*. Vol. 26 No. 4 s. 339–367. <https://doi.org/10.1111/isj.12071>
- Silva, D., Foldes, D. & Csiszar, C. (2021a). Autonomous Vehicle Use and Urban Space Transformation: A Scenario Building and Analysing Method. *Sustainability (Basel, Switzerland)*. Vol. 13 No. 6. <https://doi.org/10.3390/su13063008>
- Silva, D., Csiszar, C. & Földes, D. (2021b). Autonomous vehicles and urban space management. *Zeszyty naukowe Politechniki Śląskiej*. Vol. 110 s. 169–181. <https://doi.org/10.20858/sjsutst.2021.110.14>
- Sitra. (2023). Megatrendit 2023. Noudettu 19.1.2025 osoitteesta <https://www.sitra.fi/julkaisut/megatrendit-2023/>
- Soraya, S. (2018). Data Analytics and Big Data. *John Wiley & Sons, Incorporated*.
- Suomen Pankki. (2024). Ennustetaulukot vuosille 2024–2027 (joulukuu 2024). Noudettu 27.2.2025 osoitteesta <https://www.eurojatalous.fi/fi/2024/5/ennustetaulukot-vuosille-2024-2027-joulukuu-2024/>
- Valtioneuvosto. (2024). Tulevaisuusselonteon 1. osan strateginen toimintaympäristö-analyysi. *Valtioneuvoston julkaisuja 2024:54*. <https://urn.fi/URN:ISBN:978-952-383-553-5>
- van Der Heijden, K. (2000). Scenarios and Forecasting: Two Perspectives. *Technological forecasting & social change*. Vol. 65 No. 1 s. 31–36. [https://doi.org/10.1016/S0040-1625\(99\)00121-3](https://doi.org/10.1016/S0040-1625(99)00121-3)

- van Notten, P. W., Rotmans, J., van Asselt, M. B. & Rothman, D. S. (2003). An updated scenario typology. *Futures: the journal of policy, planning and futures studies*. Vol. 35 No. 5 s. 423–443. [https://doi.org/10.1016/S0016-3287\(02\)00090-3](https://doi.org/10.1016/S0016-3287(02)00090-3)
- Varum, C. & Melo, C. (2010). Directions in scenario planning literature – A review of the past decades. *Futures: the journal of policy, planning and futures studies*. Vol. 42 No. 4 s. 355–369. <https://doi.org/10.1016/j.futures.2009.11.021>
- Vecchiato, R. & Roveda, C. (2010). Strategic foresight in corporate organizations: Handling the effect and response uncertainty of technology and social drivers of change. *Technological forecasting & social change*. Vol. 77 No. 9 s. 1527–1539. <https://doi-org.proxy.uwasa.fi/10.1016/j.techfore.2009.12.003>
- Vuorinen, T., Huikkola, T., & Alma Talent. (2023). *Strategiakirja: 25 työkalua*. Alma Talent.
- Wack, P. (1985). Scenarios: Uncharted Waters Ahead. *Harvard business review*. Vol. 63 No. 5 s. 73–89.
- Weele, A. J. v. (2018). *Purchasing and supply chain management (Seventh edition.)*. Cengage.
- Weimer-Jehle, W. (2006). Cross-impact balances: A system-theoretical approach to cross-impact analysis. *Technological forecasting & social change*. Vol. 73 No. 4 s. 334–361. <https://doi.org/10.1016/j.techfore.2005.06.005>
- Werner, M. (1990). Planning for uncertain futures: Building commitment through scenario planning. *Business horizons*. Vol. 33 No. 3 s. 55–58. [https://doi.org/10.1016/0007-6813\(90\)90041-9](https://doi.org/10.1016/0007-6813(90)90041-9)
- Winters, R. (2017). *Practical Predictive Analytics*. Packt Publishing.
- Witkowski, K. (2017). Internet of Things, Big Data, Industry 4.0 – Innovative Solutions in Logistics and Supply Chains Management. *Procedia Engineering*. Vol. 182 s. 763–769. <https://doi.org/10.1016/j.proeng.2017.03.197>
- Yin, R. K. (2009). *Case study research: Design and methods (4th ed.)*. Sage.
- Ziegler, D., & Abdelkafi, N. (2023). Exploring the automotive transition: A technological and business model perspective. *Journal of cleaner production*, 421, 138562. <https://doi.org/10.1016/j.jclepro.2023.138562>

Liitteet

Liite 1. PESTEL-analyysi case-yrityksen toimintaympäristöstä

POLIITTISET
<ul style="list-style-type: none"> - Geopoliittinen ympäristö epävakaa -> huomioitava kansainväliset suhteet sekä mahdolliset konfliktit, jotka voi vaikuttaa esim. ajoneuvojen tuotantoon ja tuontitulleihin. (2) - EU:n ja Suomen hallituksen tavoitteet pienentää liikenteen päästöjä ohjaavat toimintaa kohti vähäpäästöisempiä käyttövoimia. (3) - Mahdolliset muutokset ajoneuvo- ja polttoaineverotuksessa voivat vaikuttaa ajoneuvoihin kohdistuvaan kysyntään. (4) - Poliittisilla päätöksillä suuri merkitys mihin suuntaan autoliikkeen toiminta kehittyy: ajoneuvoverotus sekä päästömääräykset. (7) - Autoalaan liittyviä poliittisia päätöksiä Suomen ja EU:n tasolla. (2)
EKONOMISET
<ul style="list-style-type: none"> - Talouden suhdanteet vaikuttavat suoraan liiketoimintaan. (2) - Globaalin rahoitusmarkkinoiden epävakaus kasvaa -> ajoittaiset vakavat häiriöt, rahoituksen hinnan nousu ja pahimmillaan laaja velkakriisi. (2) - Tekoälyn, automaation ja digitalisaation laaja hyödyntäminen parantavat tuottavuutta sekä yksityisellä että julkisella sektorilla. (2) - Ekologinen ilmastokriisi vaikuttaa yhä vahvemmin talouteen -> kiertotaloudesta välttämättömyys. (1)(2) - Ilmasto- ja ympäristökysymykset kriittisiä talouden kehityksessä. (2) - Työn tuottavuuden kasvun hiipuminen sekä väestön ikääntyminen heikentävät Suomen talouskasvun näkymiä. (6) - Työntekijöiden ansioiden nousu -> kuluttajien ostovoima kohenee. (9)
SOSIAALISET
<ul style="list-style-type: none"> - Väestön ikääntyminen ja työvoimapula -> maahanmuuton lisääntyminen. (6) - Muuttuvat liikkumistottumukset ja ympäristötietoisuuden kasvu -> tarve yksityisautoilulle vähenee. (2) - Kaupungistumisen jatkuminen. (2) - Autoalan murros edellyttää jatkuvaa oppimista ja uudenlaista osaamista -> jatkuva osaamisen kehittäminen korostuu. (8) - Kehittyvien digijärjestelmien myötä työn tekemisen malli muuttuu -> asiakaspalvelutyö lähes ympärivuorokautista. (8) - Pandemiat ja epidemiat yleistyvät. Luonnonympäristöjen pirstaloituminen edistää eläintautien tarttumista, ilmaston ääri-ilmiöt lisäävät tauteja ja liikkuvuus vauhdittaa tautien leviämistä. (1)
TEKNOLOGISET
<ul style="list-style-type: none"> - Sähköajoneuvojen sekä autonomisten ajoneuvojen yleistyminen jatkuu. (3) - Uusiutuvat polttoaineet tarjoavat vähäpäästöisempiä vaihtoehtoja ja voivat vähentää liikenteen päästöjä. (4) - Automatisaation ja tekoälyn kasvu -> niin ajoneuvoissa kuin yhtiöiden järjestelmissäkin. (1) - Sähköistymisen myötä murros ajoneuvojen huoltopalveluissa -> vaaditaan uutta osaamista mekaniikoilta, kun polttomoottoriajoneuvojen sijaan on huollettavana sähköajoneuvoja. (8) - Tietoturvan tärkeys -> Kyberuhkiin varautumisen merkitys korostuu entisestään. (2)
EKOLOGISET

- Suomi tavoittelee hiilineutraaliutta vuoteen 2035 mennessä. (2)
- Suomen tavoite puolittaa liikenteestä aiheutuvat päästöt vuoteen 2030 mennessä -> tavoitteen saavuttamiseksi autokannan muuttava vähäpäästöisemmäksi. (2)
- Kiertotalouden lisääntyminen. (1)
- Autokannan keskipäästöjen aleneminen kiihtyy. (5)
- EU:n alueella uusien henkilö- ja pakettiautojen myynnin oltava päästötöntä vuoteen 2035 mennessä. (3)

LAINSÄÄDÄNNÖLLISET

- Tulevaisuudessa case-yrityksen raportoitava EU:n kestävyysraportointistandardien mukaisesti.
- EU:n lainsäädännön mukaan Suomen on vähennettävä kasvihuonekaasupäästöjään 39 prosentilla vuoteen 2030 mennessä verrattuna vuoteen 2005. (7)
- Kansainvälisen lainsäädännön monimutkaistuminen, päällekkäisyydet ja poikkihallinnollisuus lisääntyy. (2)
- Lataus- ja jakeluverkostoa tukeva lainsäädäntö merkittävä käyttövoimamurroksen ajuri. (2)
- Ilmastopimus ja päästövähennystavoitteet -> liikenteen päästövähennystavoitteiden saavuttaminen vaatii sähköistymistä. (3)
- Ajoneuvojen verotuksilla merkittävä vaikutus ohjauskeinona, kun halutaan vaikuttaa kuluttajien valintoihin ja liikenteen päästöihin. (3)(7)

1. Sitran megatrendit 2023

2. Hallituksen tulevaisuusselonteko 2045 (2024)

3. AKL:n tiekartta käyttövoimista 2040 (2024)

4. LVM:n julkaisuja 2024:8

5. ETLAn skenaariolaskelmia päästöjen kehityksestä 2050 (2021)

6. Suomen Pankin ennusteet tulevaisuuden kasvunäkymistä (2025)

7. LVM:n julkaisuja 2021:15

8. Kiihdytyskaistalla tulevaisuuden osaamiseen (2021)

9. Suomen Pankin ennusteet taloustilanteesta vuosina 2024–2027 (2024)

Liite 2. Skenaarioiden taustaolettamukset

Taloukasvuskenaario	Sähkö-Suomi-skenaario	Taantumaskenaario
Vakaa poliittinen tilanne Suomessa ja EU:ssa; ajoneuvojen tuonti vaivatonta	Suomella vahva tahtotila edistää sähköistymistä (7)	Poliittinen epävarmuus ja kauppasodat heikentävät talouskasvua; ajoneuvojen tuonti haasteellista (2)
Kuluttajien ostovoima kasvaa; uusien autojen kauppa elpyy (9)	Ympäristötietoisuus ohjaa kuluttajien ostopäätöksiä (3)	Kuluttajien ostovoima heikkenee; julkisen liikenteen käyttö lisääntyy (6)
BKT kasvaa Suomessa keskimäärin 1% vuodessa (6)	BKT kasvaa, mutta sähköistymisen investoinnit voivat aluksi hidastaa kasvua (2)	Suomen BKT:n kasvu alle 1% vuodessa (6)
Valtion kannusteet sähköautojen hankintaan yleistyvät (2)	Valtion tuki sähköautojen hankinnalle voimakasta (3)	Valtio ei lisää kannusteita sähköautojen hankintaan (3)
EU:n ja Suomen kasvihuonepäästöpolitiikka jatkuu ajankohtaisena (2)	EU:ssa ja Suomessa toimet kasvihuonepäästöjen vähentämiseksi lisääntyvät ja uudistuvat jatkuvasti (4)	EU:n ja Suomen kasvihuonepäästöpolitiikka kevenee tai pysyy entisellään
Inflaation kasvu maltillista, noin 1–2% vuodessa (9)	Uusiutuvan energian myötä inflaatio hidastuu pitkällä aikavälillä (4)	Inflaatio kiihtyy; uhka stagflaatiosta
Toimittajien hinnat kasvavat kysynnän kasvaessa	Sähköautojen huoltojen kysyntä kasvaa; saataisuusongelmat (8)	Toimittajien hinnat laskevat kysynnän vähentyessä
Autoteollisuuden teknologinen kehitys jatkuu nopeana (3)	Sähköautojen ja autonomisen ajamisen teknologiat kehittyvät edelleen (1)	Autoteollisuuden investoinnit uuteen teknologiaan vähenevät; keskittyminen kustannustehokkaisiin ratkaisuihin (1)
Ympäristötietoisuuden kasvu (1)	Kestävä kehitys liiketoiminnan keskeisimpiä ajureita kohti ekologisesti kestävää taloutta (2)	Ympäristöasiat menettävät merkitystään; taloudelliset huolet etusijalla
Energiantuotanto monipuolista; fossiiliset polttoaineet edelleen merkittävässä roolissa (2)	Uusiutuvan energian osuus kasvaa merkittävästi; fossiilisten polttoaineiden käyttö vähenee huomattavasti (7)	Kustannustehokkuus tärkeintä; investoinnit uusiutuvaan energiaan vähenevät
Työllisyys kohenee; osaavan työvoiman saatavuus haasteellista (8)	Autoalan murroksessa syntyy uusia työpaikkoja, mutta vaatii uutta osaamista (8)	Työttömyys kasvaa (6)
Yritykset investoivat voimakkaasti tekoälyyn, data-analytiikkaan ja automatisaatioon tehostaakseen toimintaansa (1)	Tekoäly, data ja automatisaatio ovat avainasemassa sähköautojen ja koko liiketoiminnan kehittämisessä (2)	Investoinnit tekoälyyn ja automatisaatioon vähenevät

<ol style="list-style-type: none">1. Sitran megatrendit 20232. Hallituksen tulevaisuusselonteko 2045 (2024)3. AKL:n tiekartta käyttövoimista 2040 (2024)4. LVM:n julkaisu 2024:85. ETLAn skenaariolaskelmia päästöjen kehityksestä 2050 (2021)	<ol style="list-style-type: none">6. Suomen Pankin ennusteet tulevaisuuden kasvunäkymistä (2025)7. LVM:n julkaisu 2021:158. Kiihdytyskaistalla tulevaisuuden osaamiseen (2021)9. Suomen Pankin ennusteet taloustilanteesta vuosina 2024–2027 (2024)
--	--