Kriittisten asiakastilausten eskalointien juurisyytutkimus suuria kielimalleja hyödyntäen

Lappeenrannan–Lahden teknillinen yliopisto LUT

Tuotantotalouden diplomityö

2025

Joonas Pehkonen

Tarkastajat: Professori Timo Kärri

Tutkijatohtori Antti Ylä-Kujala

TIIVISTELMÄ

Lappeenrannan–Lahden teknillinen yliopisto LUT

LUT Teknis-luonnontieteellinen

Tuotantotalous

Joonas Pehkonen

Kriittisten asiakastilausten eskalointien juurisyytutkimus suuria kielimalleja hyödyntäen

Tuotantotalouden diplomityö

2025

87 sivua, 10 kuvaa, 8 taulukkoa ja 2 liitettä

Tarkastajat: Professori Timo Kärri

Tutkijatohtori Antti Ylä-Kujala

Avainsanat: Eskalointiprosessi, juurisyyanalyysi, toimitusketjun haasteet, generatiivinen tekoäly, suuret kielimallit

Tämä diplomityö käsittelee kriittisten asiakastilausten eskalointien juurisyiden tunnistamista ja analysointia suuria kielimalleja hyödyntäen. Työn tavoitteena oli tutkia, mitkä tekijät johtavat eskalointipyyntöjen syntymiseen sekä arvioida, kuinka tekoälypohjaiset analyysimenetelmät voivat parantaa prosessin ymmärtämistä ja kehittämistä.

Tutkimus toteutettiin tapaustutkimuksena kohdeyritykselle. Työ koostui kahdesta osasta, joista ensimmäinen oli kirjallisuuskatsaus tilausohjautuvaan tuotantoon sekä generatiiviseen tekoälyyn. Aikaisempi kirjallisuus loi pohjan työn toisessa osassa tehtävään empiiriseen tutkimukseen, jossa kuvattiin kohdeyrityksen asiakastilauseskaloinnin nykytilaa sekä tutkittiin eskalointien juurisyitä. Aineistona käytettiin kohdeyrityksen eskalointikeskusteluja vuosilta 2021–2024. Näitä eskalointikeskusteluja oli kertynyt yhteensä 7 147 kappaletta. Analyysin tueksi kehitettiin suuriin kielimalleihin perustuva analyysityökalu, jonka avulla pyrittiin tunnistamaan ja luokittelemaan eskalointipyyntöjen avaamiseen johtaneet keskeiset syyt. Menetelmä yhdisti tekstianalyysin perinteisiin tilastollisiin menetelmiin, mikä mahdollisti kattavamman tarkastelun eskalointien taustatekijöistä.

Tulokset osoittivat, että suurin osa eskalointipyyntöjä aiheuttavista ongelmista liittyy toimitusketjun epävarmuuksiin, tuotannollisiin haasteisiin ja resurssienhallinnan ongelmiin. Erityisesti materiaalien saatavuusongelmat, tuotantoprosessin häiriöt ja kapasiteettihaasteet nousivat keskeisiksi syiksi eskalointien taustalla. Tutkimus osoitti myös, että suuret kielimallit voivat merkittävästi tehostaa eskalointiprosessia ja nopeuttaa juurisyyanalyysiä, mutta niiden hyödyntäminen vaatii huolellista integrointia yrityksen tietojärjestelmiin sekä selkeää strategiaa tekoälyn roolista päätöksenteossa. Johtopäätöksenä työssä esitetään useita kehitysehdotuksia, kuten eskalointipyyntöjen avaamiskriteeristön luominen sekä toimitusketjun läpinäkyvyyden lisääminen.

ABSTRACT

Lappeenranta–Lahti University of Technology LUT

School of Engineering Science

Industrial Engineering and Management

Joonas Pehkonen

Root Cause Analysis of Critical Customer Order Escalations Using Large Language Models

Master's thesis

2025

87 pages, 10 figures, 8 tables and 2 appendices

Examiners: Professor Timo Kärri

Post-doctoral researcher Antti Ylä-Kujala

Keywords: Escalation process, root cause analysis, supply chain challenges, generative artificial intelligence, large language models

This master's thesis investigates the root causes of escalation in critical customer orders using large language models. The objective of this study was to identify the main factors leading to escalation requests and explore how artificial intelligence-based analytical methods can enhance the understanding and optimization of the process.

The thesis was conducted as a case study for the target company. It consisted of two parts, the first of which was a literature review on order-driven production and generative artificial intelligence. Previous literature provided the foundation for empirical research conducted in the second part of the thesis, which described the current state of customer order escalation in the target company and examined the root causes of escalations. The data used consisted of escalation discussions from the years 2021-2024. A total of 7,147 escalation discussions were collected. To support the analysis, an analysis tool based on large language models was developed, aiming to identify and classify the key causes that led to the initiation of escalation requests. The method combined text analysis with traditional statistical methods, enabling a more comprehensive examination of the underlying factors behind the escalations.

The results show that most of the problems causing escalation requests are related to supply chain uncertainties, production challenges, and resource management issues. Specifically, material availability issues, production process disruptions, and capacity constraints emerged as key causes behind the escalations. The study demonstrates that large language models can significantly enhance the escalation process and expedite root cause analysis, but their use requires careful integration with the company's information systems and a clear strategy regarding artificial intelligence's role in decision-making. The conclusions of the thesis propose several development suggestions, such as creating criteria for opening escalation requests and increasing transparency in the supply chain.

ALKUSANAT

Tämä diplomityö merkitsee opintojeni päätöstä LUT-yliopistossa. Olen äärimmäisen kiitollinen ystäville, joita olen saanut tämän matkan varrella. Tulen aina vaalimaan yhdessä koettuja hetkiä ja odotan innolla, mitä tulevat vuodet tuovat tullessaan.

Haluan kiittää Valmetia heidän tarjoamastaan mahdollisuudesta haastaa itseäni uusien ja mielenkiintoisten aihealueiden parissa. Kiitokset etenkin Valmetin puolen työnohjaajalle Erkille, jolta sain arvokkaita vinkkejä niin diplomityöhön kuin tulevan työurani varalle.

Lopuksi haluan myös osoittaa erityiskiitokset perheelleni ja tyttöystävälleni, joiden tuki on ollut korvaamatonta opintojeni aikana.

Helsinki 11.4.2025

Joonas Pehkonen

SYMBOLI- JA LYHENNELUETTELO

ATO	Assemble-to-Order, Tilauksesta kokoonpano
DL	Deep learning, Syväoppiminen
ETO	Engineer-to-Order, Tilauksesta suunnittelu
GAN	Generative Adversarial Network, Generatiivinen kilpaileva verkosto
LLM	Large language model, Suuri kielimalli
ML	Machine learning, Koneoppiminen
MRO	Maintenance, Repair, and Operations, Kunnossapito- ja huoltotoiminnot
MTO	Manufacture-to-Order, Tilauksesta valmistaminen
NLP	Natural language processing, Luonnollisen kielen käsittely
RAG	Retrieval-Augmented Generation, Hakupohjainen tekstinluonti

Sisällysluettelo

1 Johdanto ... 8
1.1 Työn tausta ... 8
1.2 Tavoitteet ja rajaus ... 9
1.3 Tutkimusmenetelmät ja data ... 11
1.4 Raportin rakenne ... 12
2 Teoreettinen tausta ... 15
2.1 Asiakastilausohjautuvan valmistuksen erityispiirteet ... 15
2.2 Eskalointijärjestelmän rooli tuotannon tehostamisessa ... 26
2.3 Tekoälyn määritelmä ja kehitys ... 28
2.4 Luonnollisen kielen käsittelystä suurien kielimallien läpimurtoon ... 31
2.5 Suurien kielimallien hyödyntäminen tekstianalyysin tukena ... 36
2.6 Suurien kielimallien haasteet ... 38
2.7 Kielimallien soveltaminen teollisessa ympäristössä ... 41
2.8 Teoreettisen taustan yhteenveto ... 43
3 Empiirinen tutkimus ... 45
3.1 Valmet Flow Control ... 45
3.2 Teollisuusventtiilin valmistusprosessi ... 45
3.3 Kohdeyrityksen kriittisten asiakastilausten eskalointiprosessi ... 47
3.4 Käytettävän aineiston esittely ... 50
3.5 Juurisyyanalyysin toteutus ja juurisyybotin kehittäminen ... 50
4 Tulokset ja keskustelu ... 55
4.1 Eskalointiprosessin nykytila ... 55
4.2 Juurisyyanalyysin tulokset ... 57
4.3 Juurisyybotin analysointiominaisuuksien arviointi ... 68
5 Johtopäätökset ... 70
5.1 Vastaukset tutkimuskysymyksiin ... 70
5.2 Toimenpidesuositukset ... 72
5.3 Tutkimuksen rajoitteet ja jatkotutkimuskohteet ... 76
Lähteet ... 78

Liitteet

Liite 1. Juurisyytutkimuskehote kielimallille

Liite 2. Juurisyykategorisointi

1 Johdanto

Tämä diplomityö käsittelee kriittisten asiakastilausten hallintaa eskalointiprosessista saatavan datan avulla. Suurien kielimallien kehitys on johtanut yhä tehokkaampien sovellusten kehittämiseen, mikä on johtanut siihen, että kohdeyritys haluaa analysoida myös eskalointipyyntöjen keskusteluista saatavaa strukturoimatonta dataa esikoulutettujen kielimallien avulla, perinteisen taulukkolaskenta-analyysin lisäksi. Tutkimuksen avulla pyritään tuottamaan lisätietoa kohdeyrityksen nykyisen eskalointiprosessin kehittämiseen sekä löytämään juurisyitä eskalointipyyntöjen taustalle.

1.1 Työn tausta

Valmistavan teollisuuden yritykset ovat viime vuosikymmeninä kohdanneet kasvavaa kysyntää asiakkaalle räätälöitävien tuotteiden parissa ja perinteiset tuotantostrategiat, joissa tuotteet kasataan standardikomponenteista eivät ole enää hetkeen vastanneet asiakkaiden vaatimuksia. Nämä valmistavan teollisuuden yritykset ovat joutuneet kasvavan kilpailun sekä asiakkaiden vaatimusten seurauksena kehittämään tuotantostrategioitaan ja päivittämään toimitusketjua vastaamaan tarvetta räätälöidyille tuotteille. Usean alalla toimivan yrityksen strategiaa kuvaakin nykyään tilauksesta kokoonpano (ATO), tilauksesta valmistus (MTO) tai tilauksesta suunniteltaessa (ETO) -ajattelu, joita yhdistää ajatus, että tuotantoa ei käynnistetä ennen asiakkaan tilausvahvistusta. Tämä asiakastilausohjautuva tuotanto aiheuttaa toimitusketjulle aikaisempaa suuremman paineen, sillä vain harvoja lopputuotteen komponentteja voidaan tilata varastoon. Varsinkin ETO-tilauksissa komponentit ja materiaalit ovat tarkasti räätälöityjä sekä korkealaatuisia, mikä asettaa myös toimittajat sekä alihankkijat suuremman aikataulu- sekä laatupaineen alle. (Hicks et al., 2000, 180)

Asiakastilausohjautuvaan tuotantoon tukeutuvat yritykset voivat luoda kilpailuetua toisiinsa etenkin minimoimalla toimitusaikatavoitteet sekä pysymällä projektin tarjousvaiheessa sovituissa tavoitteissa (Seth & Rastogi, 2019). Mahdollistaakseen kunnianhimoiset toimitusaikatavoitteet, yritykset pyrkivät mahdollisimman tehokkaaseen tuotantoon esimerkiksi Leanin, modernien toiminnanohjausjärjestelmien sekä tarkan

tuotannonsuunnittelun avulla. On kuitenkin mahdollista ja jopa todennäköistä, että jossain kohtaa tilaus-toimitusketjua tapahtuu ennalta arvaamattomia asioita, jotka viivästyttävät projektin aikataulua. Näitä asioita voivat olla esimerkiksi toimittajan laatuongelmat, kokoonpanon inhimilliset erheet, tuotannon hetkelliset kapasiteettiongelmat esimerkiksi laiterikkojen tai -huoltojen takia, tilausrevisiot eli tilauksen muutospyynnöt sekä monet muut tilaus-toimitusprosessin aikana sattuvat vastoinkäymiset. Edellä kuvatut haasteet herättävät asiakkaissa perusteltua huolta, sillä heidän omat projektinsa etenevät usein tiukkojen aikataulujen puitteissa. Huolenaiheen realisoituessa asiakkaan kanssa on pyrittävä minimoimaan tilauksen myöhästymä sekä löytämään kaikkia osapuolia miellyttävä ratkaisu.

Kohdeyritys on huomannut näiden tilaus-toimitusketjun ongelmien olevan lähes kroonisia ja reagoinut siihen luomalla oman eskalointiprosessin, jonka avulla projektipäälliköt sekä tilausten hallitsijat voivat avata tehtaan eri toiminnoille pyyntöjä, joissa selvitetään monen erityyppisten ongelmien laatua sekä vaikutusta tilauksen aikatauluun. Kaikista kriittisimmille asiakastilauksille tehtyjä pyyntöjä käydään läpi kaksi kertaa viikossa esihenkilötasolla. Palaveriin osallistuu edustajia mahdollisimman monesta toiminnosta, jotta kaikki näkökulmat voidaan huomioida kokonaisvaltaisesti. Edustajia on paikalla esimerkiksi projektinhallinnasta, hankinnasta, kokoonpanosta, tuotannonsuunnittelusta, koneistuksesta sekä laatuosastolta. Kohdeyritys on havainnut, että eskalointipyyntöjen lukumäärä on viime vuosina kasvanut, mikä kuormittaa yhä laajemmin eri toimintoja. Tämän vuoksi kohdeyritys haluaa tutkia tämän eskalointiprosessin nykytilaa sekä juurisyitä näiden pyyntöjen taustalla, jotta toimintaa vodaan tehostaa.

Kohdeyritys on kiinnostunut myös tekoälykentän viimeaikaisista kehitysaskeleista ja haluaa tutkia, voisiko suuria kielimalleja hyödyntää tämän juurisyyanalyysin tukena. Tässä tutkimuksessa suurilla kielimalleilla pyritään analysoimaan strukturoimatonta tekstidataa, jossa käsitellään kohdeyrityksen tilaus-toimitusketjun haasteita ja niiden vaikutuksia aikatauluun.

1.2 Tavoitteet ja rajaus

Työn tavoitteena on tutkia valmistavan teollisuuden tapoja käsitellä kriittisissä asiakastilauksissa ilmeneviä ongelmia ja riskejä erityisesti reaktiivisesta näkökulmasta sekä

analysoida näiden riskien toteutumisen juurisyitä kohdeyrityksessä. Tämän työn tutkimuskysymykset ovat seuraavat:

1. Mitkä ovat juurisyyt eskalointipyynnön avaamiselle?
2. Miten suuria kielimalleja voidaan hyödyntää eskalointidatan analysoimisessa?
3. Miten eskalointiprosessia voi kehittää juurisyyanalyysin pohjalta?

Ensimmäisen tutkimuskysymyksen avulla pyritään tutkimaan, miksi eskalointipyyntöjä avataan ja mihin niillä pyritään. Tarkoituksena on tunnistaa, voiko pyyntöjen juurisyitä luokitella eri toimijoiden mukaan. Tutkimus tehdään vuosina 2021–2024 avattuja pyyntöjä analysoimalla.

Toisen tutkimuskysymyksen avulla pyritään tutkimaan, voidaanko kielimalleja hyödyntää vapaamuotoisen tekstin analysoimisessa ja luokittelussa. Tutkimuskysymykseen pyritään löytämään vastaus hyödyntämällä teoreettista viitekehystä. Viitekehyksen avulla muodostetaan käsitys suurien kielimallien mahdollisuuksista tekstianalyysissa sekä kartoitetaan keinoja, joilla kielimallin tulokset ovat mahdollisimman laadukkaita. Lisäksi tutkitaan, miten kielimallien avulla saadut tulokset tukevat perinteisiä taulukkolaskennan keinoja.

Kolmannen tutkimuskysymyksen avulla pyritään yhdistämään empiiriset tulokset teoreettiseen taustaan, jotta voidaan tunnistaa kriittisimmät kehityskohdat eskalointiprosessissa sekä toimitusketjussa. Tutkimus tehdään ensimmäisen tutkimuskysymyksen tulosten perusteella vertaamalla niitä myös kirjallisuudessa esiintyviin ratkaisumalleihin ja -ehdotuksiin.

Työ rajataan valmistavan teollisuuden tilausohjautuvassa ympäristössä toimivien yritysten tilaus-toimitusketjussa ilmeneviin riskeihin. Riskien käsittelyssä keskitytään teknisiin sekä operationaalisiin ongelmiin eli makrotason häiriöt jäävät rajauksen ulkopuolelle. Suuria kielimalleja käsitellään työssä käytännönläheisestä näkökulmasta, eikä valittua kielimallia ole tarkoitus kouluttaa käytännössä. Ainoa konteksti, joka kielimallille annetaan, on sisällytettynä sille annettuun kehotteeseen sekä RAG-tietokantaan.

1.3 Tutkimusmenetelmät ja data

Työn pääasiallisena tutkimusmenetelmänä toimii tapaustutkimus, joka koostuu teoreettisesta sekä empiirisestä osuudesta. Tapaustutkimus on perusteellinen tutkimus aiheesta todellisessa ympäristössä (Saunders et al., 2015). Tapaustutkimuksen kohde on kohdeyrityksen toimitusketjuun liittyvä sekä etenkin tuotantoon painottuva eskalointiprosessi. Tämä tapaustutkimus on pääosin laadullinen kohdeyrityksessä havaitusta ongelmasta, mutta työ sisältää elementtejä myös tilastollisesta tutkimuksesta. Tuomi & Sarajärvi (2018) toteavat laadullisen tutkimuksen omaavan kolme erilaista analyysimuotoa: aineistolähtöinen-, teoriaohjaava- sekä teorialähtöinen analyysi. Tässä työssä hyödynnetään aineistolähtöistä analyysiä. Teoriaohjaavassa analyysissä teoria toimii työn apuna, mutta analyysi ei pohjaudu suoraan teoriaan vaan myös empiiriseen tutkimusaineistoon. Tutkimuksen teoreettinen osa keskittyy tilaus-toimitusketjun riskeihin sekä niiden ratkaisuihin ja generatiivisen tekoälyn mahdollisuuksien kartoittamiseen tekstianalyysin tukena. Tämän kuvailevan kirjallisuuskatsauksen tavoitteena on luoda ymmärrys eri näkökulmista ja malleista, joita on syytä ottaa huomioon, ja näin tukea tutkimuksen tavoitteiden saavuttamista.

Ensimmäiseen tutkimuskysymykseen on tarkoitus löytää perusteeksi valmistavan teollisuuden tilaus-toimitusketjuissa ilmenevistä ongelmista kertovia tutkimuksia, jotta voidaan määritellä ovatko kohdeyrityksen ongelmat alalle tyypillisiä. Kirjallisuutta on etsitty hakusanoilla ja niiden yhdistelmillä, kuten ”ATO”, ”ETO”, ”MTO”, ”Supply chain issues”, ”ETO/MTO supply chain characteristics”, sekä ”Production disruption”. Erityisesti rakennusalaan liittyvien tutkimusten osuus on pyritty minimoimaan, jotta tarkastelussa voidaan keskittyä erityisesti teolliseen toimintaympäristöön.

Toiseen tutkimuskysymykseen pyritään vastaamaan samantyylisesti kuin ensimmäiseen: Ensin luodaan kattava teoreettinen viitekehys ja sitten kohdeyrityksen datan analysointi. Kirjallisuuden hakusanoja on etsitty esimerkiksi seuraavilla hakusanoilla ”Artificial intelligence”,” Machine learning”,” Large language models”,” Large language models in analytics”,” Large language models data security”, “Fine-tuning LLM”, “Retrieval augmented generation” ja” Utilizing Large language models for text analysis”.

Kolmanteen tutkimuskysymykseen kerättiin artikkeleita sekä tutkimuksia, joissa käsitellään teollisuudessa esiintyviä eskalointiprosesseja, jotta riittävän teoreettisen taustan saa luotua.

Kysymykseen vastattu kirjallisuustutkimuksen sekä empiiristen havaintojen perusteella. Kirjallisuutta on etsitty hakusanoilla, kuten ”reactive supply chain risk management”, “Supply chain expediting practices”, “Cross-functional decision making”, “Delay management”,” Order escalation” ja “Resource constrained multi-project management” sekä näiden yhdistelmillä. Kaikkiin tutkimuskysymyksiin etsittiin lähteitä pääosin LUT Primosta, mutta myös Scopusta hyödynnettiin.

Työn empiirisessä osuudessa ratkaisuja pyritään löytämään juurisyyanalyysin eli RCA:n (engl. Root cause analysis) avulla. RCA perustuu siihen, että tehtävät päätelmät perustuvat faktoihin ja analyyseihin, ei oletuksiin, muihin päätelmiin tai hypoteeseihin. RCA:ssa yritetään löytää tapa parantaa käytänteitä ja johtamista, jotta sama ongelma ei esiinny uudestaan. Kolme tärkeintä kysymystä RCA:ta läpikäydessä ovat: mitä tapahtui, miten se tapahtui ja miksi se tapahtui? (Otegui 2014, 183; Moore 2007, 286)

Tässä työssä hyödynnettiin generatiivisen tekoälyn sovelluksia, kuten Microsoftin Copilotia sekä OpenAI:n ChatGPT:tä tiedon jäsentämiseen, kielen tarkentamiseen ja tekstin selkeyttämiseen.

1.4 Raportin rakenne

Tutkimus koostuu viidestä pääluvusta. Ensimmäisenä on työn johdanto, jossa kuvataan työn tausta, tutkimusongelma, työtä koskevat rajoitteet ja työn tutkimuskysymykset. Lisäksi kappaleessa kuvataan työssä käytettävä tutkimusmenetelmä. Toinen kappale käsittelee työssä käytettävää teoriaa. Kappaleessa esitellään työn kannalta tärkeimmät teoriat liittyen asiakastilausohjautuvan toimitusketjun erityispiirteisiin, eskalointijärjestelmän hyötyihin sekä generatiivisen tekoälyn mahdollisuuksiin liiketoiminnan kehittämisessä. Kappaleen tarkoitus on antaa lukijalle kuva, miten generatiivinen tekoäly voi myötävaikuttaa valmistavan teollisuuden yritysten kykyyn analysoida toimintaansa. Samalla lukija ymmärtää generatiivisen tekoälyn sekä kielimallien kouluttamisen perusperiaatteet.

Kappaleessa kolme esitellään kohdeyrityksen valmistusprosessi sekä perehdytään yrityksen käyttämään eskalointijärjestelmään, jonka jälkeen kuvataan tutkimusongelma kohdeyrityksen näkökulmasta. Kappaleen kolme lopussa esitellään tarkemmin työssä käytettävä aineisto, tutkimusmenetelmät ja syvennytään suureen kielimalliin pohjautuvan

juurisyybotin toimintaan. Kappaleessa neljä esitellään työn tulokset, jotka muodostavat eskalointiprosessin juurisyyanalyysin. Juurisyyanalyysi perustuu sekä strukturoidusta, että strukturoimattomasta datasta kerättyihin tietoihin, ja analyysin perustana käytetään kirjallisuuskatsauksen eli kappaleen kaksi havaintoja.

Kappale viisi on työn viimeinen kappale, jossa kootaan vastaukset tutkimuskysymyksiin sekä johtopäätökset tulosten pohjalta. Kappaleessa esitellään myös toimenpide-ehdotukset löydösten pohjalta ja pohditaan työn rajoitteita sekä jatkotutkimuskohteita.

Työn rakenne etenee seuraavasti: kirjallisuuskatsaus esittelee olennaiset teoriat ja antaa lukijalle riittävän pohjan empiiriseen osaan. Tämän jälkeen lukija pystyy yhdistämään teorian kohdeyritykseen ja tutkimusongelmaan. Empiirisessä osassa hyödynnetään tuotettua teoriaa, jonka avulla luodaan pohja analyysille sekä juurisyybotille ja analysoidaan käytännössä teorian esittämiä viitekehyksiä. Taulukossa 1 esitetään työn input/output -kaavio, joka kuvaa työn rakennetta.

Taulukko 1. Raportin rakenne.

Input	Kappale	Output
Työn yleinen informaatio ja tutkimusmenetelmä.	**Johdanto**	Työn tausta, tutkimuskysymykset, rajoitteet, tavoitteet sekä rakenne.
Kirjallisuus tilausohjautuvan tuotannon toimitusketjun erityispiirteistä sekä generatiivisen tekoälyn mahdollisuuksista liiketoiminnan kehittämisessä.	**Teoreettinen tausta**	Ymmärrys toimitusketjun eri toimintojen haasteista sekä mahdollisista ratkaisuista ja käsitys siitä, miten kielimalleja hyödynnetään analysoinnin tukena.
Kohdeyrityksen tuotanto- ja eskalointiprosessin kuvaus. Strukturoidun sekä strukturoimattoman datan kerääminen kohdeyrityksen tietojärjestelmistä.	**Empiirinen tutkimus**	Ymmärrys kohdeyrityksen tuotanto- ja eskalointiprosessista. Juurisyyanalyysin toteutuksen sekä juurisyybotin luomisen kuvaus.
Kirjallisuuskatsauksen tulokset sekä data kohdeyrityksen tietokannasta.	**Tulokset**	Eskalointiprosessin juurisyyanalyysi.
Kirjallisuuden ja aineiston analysoinnin tulokset.	**Johtopäätökset**	Vastaukset tutkimuskysymyksiin, työn johtopäätökset sekä jatkotutkimusehdotukset.

2 Teoreettinen tausta

Työn teoreettisen taustan kokoaminen aloitetaan asiakastilausohjautuvan tilaus-toimitusketjun erityispiirteiden kartoittamisella, josta siirrytään teollisissa toimitusketjuissa sekä tuotannossa ilmenevien riskien käsittelyyn ja teollisuudessa esiintyviin eskalointijärjestelmiin. Lopuksi perehdytään tekoälyn kehitykseen ja syvennytään kielimallien mahdollisuuksiin tekstianalyysin tukena myös teollisessa kontekstissa.

2.1 Asiakastilausohjautuvan valmistuksen erityispiirteet

Valmistavalla yrityksellä on useita menetelmiä valittavanaan, kun se pyrkii optimoimaan tuotantoaan vastaamaan markkinan kysyntään. Teollisessa ympäristössä erilaisia tuotantostrategioita ovat esimerkiksi varastoon valmistaminen (MTS), tilauksesta kokoonpano (ATO), tilauksesta valmistaminen (MTO) sekä tilauksesta suunnittelu (ETO) (Pereira et al., 2022). Erityisesti MTS on tarkoitettu enimmäkseen massatuotetuille tuotteille, joiden kustomointimahdollisuudet on minimoitu eivätkä ne täten ulotu tämän diplomityön rajaukseen. ATO- ja MTO-toimitusketju puolestaan sallivat hieman suuremman kustomoinnin, mutta tuotteet kasataan usein vakio-osista ilman erillistä ja ainutlaatuista suunnitteluprosessia (Pereira et al., 2022). Spektrin toisessa päästä löytyvät ETO-tuotteita valmistavat yritykset, jotka ovat tyypillisesti erikoistuneet valmistamaan monimutkaisia tuotteita, joissa suunnittelun korkea laatu sekä kustomointimahdollisuudet, tuotteiden monimutkaisuus, projektituotanto, alhainen volyymi sekä asiakaskeskeisyys korostuvat (Kuva 1). (Fortes et al. 2023, 1729; Adrodegari et al. 2015; Hicks et al., 2000, 180; Seth & Rastogi, 2019)

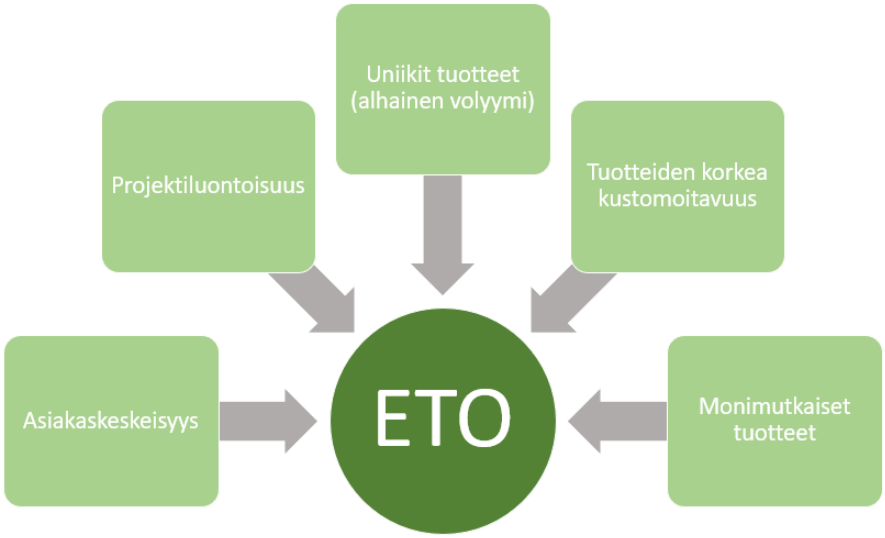

Kuva 1. ETO-yrityksen tyypilliset ominaisuudet (mukaillen Fortes et al. 2023, 1729)

Kun valmistavan teollisuusyrityksen prosessit kohtaavat korkeat laatuvaatimukset, kustomoitavat tuotteet sekä asiakkaiden toimitusaikavaatimukset, on riskipotentiaali korkeampi verrattuna massatuotantoon. Adrodegari et al. (2015, 911) nostaa ETO-yrityksille tyypillisiksi riskeiksi kapasiteettihaasteet, myöhästymät, epävarmuuden asiakasspesifikaatioissa sekä asiakkaiden tekemät muutokset jopa kesken tuotannon. Fortes et al. (2023, 1724) puolestaan nostaa esille lattiatason toiminnan, joka vaatii erityistä ammattitaitoa niin koordinoinnista kuin itse tuotannosta. Ongelmat ammattitaidossa tai koordinoinnin puute voivat johtaa esimerkiksi tuotteiden vaurioitumiseen sekä hyödyntämättömään kapasiteettiin. Aikataulun kannalta on usein myös ongelmallista, että asiakas voi olla mukana kaikissa projektin vaiheissa, kuten suunnittelussa, tuotannossa sekä testauksessa. Tämä voi johtaa odottamattomiin muutoksiin tuotteiden yksityiskohdissa tai aikatauluviivästyksiin esimerkiksi testausvaiheen aikatauluja sopiessa (Husejnagić & Sluga, 2015, 1975–1976). Näihin ongelmiin reagoiminen vaatii erityistä aktiivisuutta kaikilta tehtaan toiminnoilta, myyntiorganisaatiolta, projektipäälliköiltä ja jopa asiakkaalta, jotta asiakastilaukset etenevät aikataulussa suunnitteluvaiheesta asiakkaan haltuun. Seuraavaksi esitellään tilausohjautuvassa tuotannossa yleisesti käytössä olevaa tilausprosessi. Tämän jälkeen analysoidaan tilaus-toimitusketjun riskialttiita osia.

Asiakastilausohjautuvaa tuotantomallia soveltavissa yrityksissä tilausprosessi alkaa usein asiakkaan tarpeen määrittelyllä. Kun asiakas on päättänyt tilata yrityksen tuotteen ja hyväksyy yrityksen tarjouksen, alkaa prosessi tuotteen yksityiskohtaisella suunnittelulla,

josta siirrytään tuotannon suunnitteluun, osien valmistukseen, materiaalien sekä komponenttien ostamiseen, kokoonpanoon sekä lopulta valmiin tuotteen toimitukseen. (Fortes et al., 2023; Bermeio et al., 2023; Hicks et al., 2000; Seth & Rastogi, 2019)

Ennen kuin tilausohjautuvassa ympäristössä toimivalle yritykselle tyypillisiin ongelmiin voi syventyä, on välttämätöntä muodostaa laaja kokonaiskuva toimitusketjussa sekä tuotannossa ilmenevien ongelmien mahdollisista aiheuttajista sekä syy-seuraussuhteista. Tämän kokonaiskuvan muodostaminen aloitetaan tarkastelemalla valmistavan sekä tilausohjautuvan tuotannon tyypillistä tilaus-toimitusketjua. ETO-toimitusketju eroaa muiden tuotantostrategioiden toimitusketjuista kohdennuspisteen (engl. Decoupling point) sijainnin osalta. Kohdennuspiste sijaitsee suunnitteluvaiheessa, mikä johtaa siihen, että tuotanto käynnistyy vasta asiakkaan erityisvaatimusten pohjalta. Nämä erityisvaatimukset tekevät toimitusketjusta poikkeuksellisen, sillä komponenttien sekä materiaalien tilaaminen etukäteen ei usein ole järkevää tai edes mahdollista, mikä johtaa aikataulupaineeseen komponenttien sekä materiaalien hankinnassa. Myös MTO- ja ATO-toimitusketjussa tuotanto aloitetaan tyypillisesti vasta ostopäätöksen jälkeen (Gosling & Naim, 2009; Hicks et al., 2000; Seth & Rastogi, 2019; Pereira et al., 2022)

Fortes et al. (2023, 1729–1733) tutkivat ETO-yritysten ominaispiirteitä sekä niihin liittyviä toimintoja, jotka mahdollisesti aiheuttavat ongelmia tilaus-toimitusketjun aikana. He päätyivät Kuvan 2 mukaiseen malliin, jossa ETO-yrityksen keskeiset ominaispiirteet on jaettu neljään pääkategoriaan: projektiluontoisuus, uniikit tuotteet, asiakaskeskeisyys ja kustomoitavuus sekä monimutkaiset tilaukset. Jokaisessa pääkategoriassa on useita alakategorioita, jotka kukin aiheuttavat omat erityiset haasteensa projektin toteutukselle. Nämä alakategoriat muodostavat viitekehyksen ETO-ympäristössä toimivan teollisuusyrityksen toiminnan tarkastelulle ja niitä hyödynnetään työn empiirisessä osuudessa tilaus-toimitusprosessissa ilmenevien ongelmien analysoinnissa. Esimerkiksi projektiluontoisuus jakautuu Fortesin et al. (2023, 1728–1729) mukaan kolmeen keskeiseen alakategoriaan, jotka voivat aiheuttaa riskejä projektin etenemiselle: tarjousten laatiminen, suunnittelumuutokset ja tuotannonsuunnittelun toteutus.

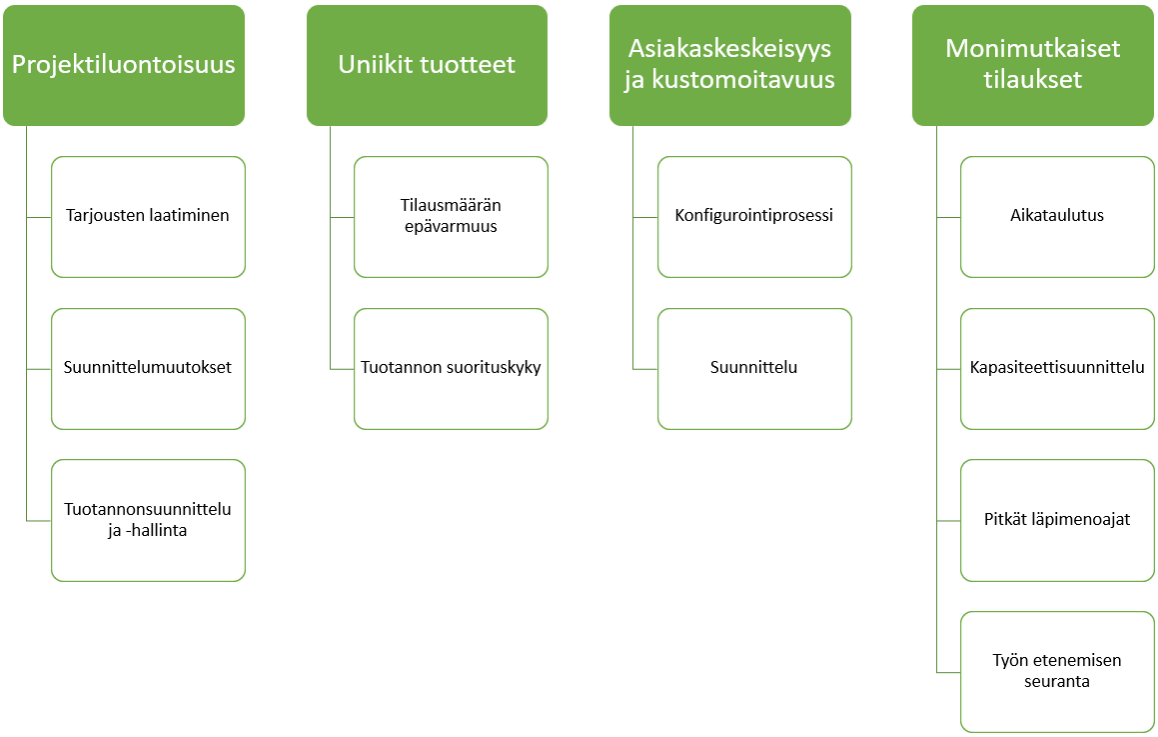

Kuva 2. ETO-yrityksen ominaispiirteet (Mukaillen Fortes et al., 2023, 1732)

Asiakastilausohjautuvassa markkinassa ja etenkin ETO-ympäristössä kyky toimittaa tuotteet mahdollisimman nopeasti ja lopulta vielä pysyä luvatussa aikataulussa on keskeinen kilpailutekijä, jota voidaan parantaa etenkin lyhentämällä läpimenoaikaa ja lisäämällä sen ennustettavuutta (Seth & Rastogi, 2019, 264). Läpimenoajan ennustettavuutta voi lisätä esimerkiksi toimitusaikapuskureilla sekä aikaisemmista kokemuksista oppimalla (Seth & Rastogi, 2019, 264). Myös MTO-ympäristön tutkimushavainnot liittyvät toimitusajan lyhentämisen merkittävään vaikutukseen kannattavuuden parantamiseksi (Pekgün et al., 2017; Benioudakis et al., 2021). Läpimenoaikaa lyhennetään esimerkiksi vähentämällä tuotannon yksittäisiin prosesseihin kuluvaa aikaa ja lisäämällä peräkkäisten toimintojen limittäisyyttä (Hicks et al., 2000, 188). Teknologiset innovaatiot voivat tehostaa tuotantoa esimerkiksi koneistuksen tai kokoonpanon osalta. Toimitusvarmuutta voidaan tehostaa yhtä lailla lisäämällä tuotteiden sekä prosessien standardisointia ja modularisointia. (Seth & Rastogi, 2019, 264-265)

Kumarin ja Singhin (2020) mukaan joustavuus on keskeinen tekijä asiakastilausten hallinnassa ja kilpailuedun saavuttamisessa – mutta mitä se käytännössä tarkoittaa? Teollisessa kontekstissa sitä voidaan tarkastella usealla eri tasolla: se voi heijastaa strategisella tasolla asiakkaiden kokonaiskysynnässä tapahtuvia pitkäaikaisia sekä

järjestelmällisiä muutoksia tai operatiivisella tasolla satunnaisia, ennakoimattomia ja lyhytaikaisia muutoksia (Kumar & Singh, 2020; Forslund & Mattson, 2021). Tuotannon joustavuutta voidaan hallita erilaisilla kapasiteetin hallinnan sekä tuotannonsuunnittelun keinoilla, mutta usein valmistavan teollisuuden yritykset kohtaavat myös tavarantoimittajista johtuvia haasteita. Toimittajien komponentit voivat tuottaa jopa 60–80 % kokonaiskustannuksista valmistavalle yritykselle, mikä osoittaa toimittajien suuren roolin asiakastilauksissa (Wagner et al., 2018). Useat tutkijat ovat tarkastelleet liiketoiminnan joustavuutta ja todenneet, että toimittajien roolin kasvu on nouseva trendi (Forslund & Mattson, 2021; Ustundag & Ungan, 2020; Kumar & Singh, 2020; Gligor, 2018).

Materiaali- ja komponenttisaatavuuden lisäksi valmistavan teollisuuden toimitusketjun yleisiä ongelmia ovat tuotantokoneiden hajoaminen sekä huollosta johtuva laitteiden alasajo, työntekijävajaus, sekä kuljetukseen liittyvät ongelmat (Kanike, 2023). Kohdeyritykselle merkityksellisimpiä ongelmien alahaaroja ovat 1. Uudelleentyöstö (engl. Rework), jossa tuotteita joudutaan korjaamaan tuotantovirheen tai laatuongelman takia tai muuttamaan teknisesti toimivaa tuotetta asiakkaan toiveesta sekä 2. Resurssiongelmat, jotka esimerkiksi Pingjuan et al. (2005) jakaa jo aiemmin esiteltyyn materiaalisaatavuuteen sekä koneiden kapasiteettiin. (Mello et al., 2015; Hicks et al., 2001, 190; Caron & Fiore, 1995; Chopra & Sodhi, 2004)

Toimitusketjuissa on useita muitakin ongelmia, jotka voivat olla universaaleja tai toimialasta riippuvaisia, mutta esimerkiksi makrotason muutoksista aiheutuneet haitat eivät kuulu tämän diplomityön rajaukseen. Kohdeyrityksen näkökulmasta kaikista merkittävimmät ongelmat voidaan jakaa kolmeen kategoriaan, mitkä ovat materiaali- ja komponenttihankinta, oman tuotannon suorituskykyyn liittyvät ongelmat sekä uudelleentyöstö, joten seuraavissa kappaleissa näihin ongelmiin perehdytään kustakin näkökulmasta.

Materiaalien ja komponenttien saatavuuden näkökulma

Alun perin Hicksin et al. (2000, 183–184) sekä myöhemmin esimerkiksi Sethin ja Rastogin (2019, 269) mukaan ETO-yritykset voidaan luokitella muun muassa niiden vertikaalisen integraatiotason mukaan. Tällöin toisessa ääripäässä ovat yritykset, jotka valmistavat kaikki komponentit itse ja suorittavat kokoonpanon myös omissa tiloissaan. Toisesta ääripäästä löytyy puolestaan yritykset, jotka toimivat lähinnä suunnittelu- ja alihankintaorganisaatioina (Hicks et al., 2000; Seth & Rastogi, 2019). Optimaalista tasoa hakiessaan, yritykset joutuvat

harkitsemaan useita eri yksityiskohtia. Näitä ovat esimerkiksi asiakkaan toimitusaikojen ja käytettävissä olevan kapasiteetin yhteensovittaminen, kustannusten alentaminen, pääoman saatavuus laiteinvestointeihin, tehtaiden mahdollinen käyttöaste sekä toimitusketjun joustavuus. Usein valmistavan teollisuuden yritykset sijoittuvat tämän spektrin keskivaiheille, sillä on tyypillistä, että useita komponentteja sekä materiaaleja hankitaan suoraan alihankkijoilta. Erityisesti materiaaleja saatetaan jatkojalostaa vielä esimerkiksi koneistamalla ennen varsinaista kokoonpanoa. Lähestymistapa vaihtelee yritysten välillä, mutta yleinen käytäntö on ollut keskittyä vähintään lopputuotteen kokoonpanoprosesseihin, koska niiden katsotaan tuottavan suurinta lisäarvoa arvoketjussa. (Hicks et al., 2000, 183–184; Seth & Rastogi, 2019, 269)

ETO-yritysten trendeiksi arvioitiin 2000-luvulle edetessä pääkeskittymiskohtien ulkopuolelle jäävien toimintojen ulkoistaminen, alihankkijoiden lukumäärän alentaminen, sekä pitkäaikaisten kumppanuussuhteiden luominen (Hicks et al., 2000, 183–184). Seth & Rastogi (2019, 262) nostavat 19 vuotta myöhemmin edelleen samoja teemoja artikkelissaan, joten arvion voidaan katsoa ainakin jollain tasolla pitävän paikkaansa. MTO-toimitusketjussa viimeaikaisena trendinä on useamman tutkimuksen mukaan ollut komponenttien sekä materiaalien hankkiminen useammasta lähteestä, mikä lisää toimitusketjun joustavuutta, mutta toisaalta se on saattanut osaltaan vaikuttaa siihen, että kumppanuussuhteet eivät välttämättä ole niin syviä kuin aikaisemmin (Leng & Parlar, 2010; Li & Wormer, 2012; Sarkar et al., 2022)

ETO-yritysten tilaus-toimitusketjun ominaispiirteet eli kohdennuspisteen sijainti suunnitteluvaiheessa, alihankkijoiden hyödyntäminen sekä suuren lisäarvon luominen kokoonpanovaiheessa ohjaavat keskustelun kohti hankinnan tehokkuutta. Hankintapäätöksiä voidaan tehdä tilaus-toimitusketjun eri vaiheissa riippuen siitä, kuinka standardoituja konfiguraatioita yritys onnistuu kehittämään. Yleisesti standardoidut konfiguraatiot mahdollistavat komponenttien ostopäätöksen tekemisen myöhemmin, mikä antaa enemmän liikkumavaraa yrityksen sisäisten funktioiden väliselle tiedonsiirrolle. Hicksin et al. (2000, 187–188) mukaan hankintafunktion tehokkuuden määrittävistä tekijöistä yksi kriittisimmistä oli standardoitujen konfiguraatioiden korkea määrä tuotetta määrittäessä. Merkittävä huomio oli myös se, että jos valmistava yritys on ollut aikaisemmin kykenevä tuottamaan nykyisin alihankkijalta ostettavat tuotteet itse, on sen tarvemäärittelyt

usein liian yksityiskohtaisia standardoinnille. Liian yksityiskohtaiset pyynnöt puolestaan lisäävät komponentin läpimenoaikaa sekä hintaa (Hicks et al., 2000, 188).

Materiaali- ja komponenttihankinnan rooli on projektin toteutuksen kannalta tärkeä, sillä valmistava yritys ei usein voi aloittaa tuotteen valmistamista ennen kuin kaikki komponentit ovat saapuneet ja materiaalit ovat valmiina. Yleiset ongelmat materiaali- sekä komponenttihankinnassa voidaan jakaa esimerkiksi Sawikin (2011) mukaan operationaalisiin sekä disruptioriskeihin. Tässä diplomityössä keskitytään vain operationaalisiin ongelmiin. Operationaalisilla riskeillä tarkoitetaan usein epävarmuuksia hinnassa, toimitusvarmuudessa sekä laadussa (Sawik, 2011). Handayani (2018) puolestaan jaottelee toimittajariskit seuraaviin luokkiin: laatu, hinta, toimitusvarmuus, tuotannon kyvykkyys, joustavuus, tietotaito, onnettomuudet, inhimillinen erehdys sekä johtajuuteen liittyvät ongelmat. Handayanin (2018) mukaan keskeisimpiä– ja kohdeyrityksen kannalta olennaisimpia– riskejä ovat materiaalien saatavuusongelmat, toimitusten viivästyminen, kyvyttömyys vastata äkillisiin tarpeisiin, materiaalivauriot sekä tilaajan myöhäinen ostopäätös.

Hicks et al. (2000, 187–188) tutkivat myös, kuinka hankinnan ja yrityksen muiden funktioiden välistä suhdetta voisi parantaa, jotta yrityksen sisäiset prosessit olisivat mahdollisimman tehokkaita. Ensimmäinen löydös oli, että tehokas tiedon jakaminen vaatii yhteisiä tietokantoja, jotka tukevat tarjous-, suunnittelu- ja hankintavaihetta sekä myös projektinhallintaa tilauksen edetessä. Tietokannoista tulee löytyä tiedot ainakin aikaisemmista konfiguraatioista ja standardikomponenteista yhdessä kustannusten, suunnittelun ja alihankinnan suorituskyvyn kanssa. Toinen löydös oli jo aiemmin mainittu kustomoinnin rajoittaminen käyttämällä modulaarisia konfiguraatioita ja standardikomponentteja. Tämä antaa hankintafunktiolle joustavuutta hankintapäätöksiä tehdessä ja parhaimmillaan se vähentää kustannuksia sekä läpimenoaikaa. (Hicks et al., 2000, 187–188; Seth & Rastogi, 2019, 264)

Forslund ja Mattson (2021) esittivät artikkelissaan useita keinoja, joilla toimittajat voivat vastata asiakkaiden muuttuvaan kysyntään. Merkittävimmät löydökset voitiin jakaa kahteen ryhmään: komponenttien saatavuuteen sekä toimitusajan hallintaan. Tavaroiden saatavuudessa yleisimmät ja tehokkaimmiksi koetut tavat olivat väliaikaisten alihankkijoiden käyttäminen, toimittajan sekä asiakkaan sopimus tietystä turvavarastosta, tiedon välittäminen toimittajille tulevasta kysynnästä mahdollisimman aikaisin ja kaikkien

muutosten viestiminen välittömästi, ylitöiden hyödyntäminen sekä tilausten jakaminen useampaan erään. Toimitusajan hallinnassa tehokkaimmaksi todettuja keinoja olivat toimitusaikapuskuri, nopeampien kuljetusmuotojen käyttäminen sekä jatkuva yhteydenpito toimittajan ja asiakkaan välillä. Useat toimittajat kertoivat viestivänsä asiakkaidensa kanssa lähes päivittäin. Informaation jakamisen toimittajan ja valmistajan välillä on todettu useissa tutkimuksissa olevan hyödyllistä toimitusketjun tehokkuuden kannalta (Goswami et al., 2013; Hsu et al., 2008). Luottamuksellisen ja kriittisen tiedon jakaminen toimitusketjussa voidaan Goswamin et al. (2013) ja Hsun et al. (2008) mukaan jakaa taktiseen sekä strategiseen tietoon. Taktinen tieto sisältää esimerkiksi toimitusaikataulut, hankinnan ja logistiikan, kun taas strateginen tieto sisältää usein markkinointi- ja asiakkuusinformaatiota sekä yrityksen pitkän aikavälin tavoitteiden jakamista. Etenkin taktisen tason tiedon jakaminen auttaa konkreettisesti kehittämään toimitusketjua. Zhoun ja Bentonin (2007, 1353–1353) taktisen informaation jakamisesta tuo toimitusketjun jäsenille kolme keskeistä hyötyä:

1. Tiedon lähettäjät ja vastaanottajat pääsevät lähemmäs toisiaan.
2. Tieto jakautuu tehokkaasti koko toimitusketjun sisällä.
3. Toimitusketjun jäsenet voivat reagoida uuteen tietoon oikea-aikaisesti.

Shin et al. (2019) puolestaan korostavat artikkelissaan lopputuotteen valmistajille Leanin mukaista lähestymistä toimittajiin, eli toimittajien määrän vähentämistä, tiedon avointa levittämistä, sekä selkeiden kommunikointikanavien luomista, mitkä johtavat pitkällä aikavälillä syvempään kumppanuussuhteeseen sekä parempiin tuloksiin. Chen et al. (2015) havaitsivat kuitenkin tutkimuksessaan autoteollisuuden kontekstissa täysin avoimen tiedonjaon joissain tilanteissa jopa heikentävän toimitusketjun suorituskykyä. Heidän mukaansa joskus valmistava yritys voi nostaa tuotantoaan yli optimin, silloin kun he odottavat toimittajalta lopullista toimitusta suurempaa saapumiserää. Useiden tutkimusten perusteella avoimempi tiedonjakaminen sekä integroitujen järjestelmien hyödyntäminen näyttäisivät kuitenkin parantavan toimitusketjun suorituskykyä. (Zhou & Benton, 2007, 1355; Lee & Whang, 2004; Wu et al., 2014; Shin et al., 2019; Forslund & Mattson, 2021).

Henry Xu (2020) tutki julkaisussaan erityisesti MTO-toimitusketjuissa esiintyvien häiriöiden kerrannaisvaikutuksia tilauksen kokonaismyöhästymiseen ja sitä, miten tätä kerrannaisvaikutusta voisi minimoida. Hänenkin näkemyksensä kerrannaisvaikutusten

minimoimiseen oli toimitusketjun läpinäkyvyyden lisääminen. Hänen mukaansa ongelman ydin on usein asiakkaan herääminen tilauksen myöhästymiseen vasta, kun tilauksen pitäisi olla valmiina toimitukseen tai jo asiakkaalla riippuen sovituista ehdoista. Asiakkaan reaktio käynnistää ketjureaktion, jolla pyritään minimoimaan myöhästymää ja maksimoimaan asiakkaan tyytyväisyys. Henry Xu (2020, 398) ehdotti ratkaisuksi asiakkaan ja toimittajan välillä olevaa liikennevalomallia, joka automaattisesti ilmoittaa asiakkaalle mahdollisesta myöhästymästä: Vihreä valo kuvastaa normaalitilannetta, keltaisen valon aikaan tilaus ei ole edennyt normaalissa tahdissa, mutta myöhästymä on kurottavissa ja punainen valo näyttää, että tilaus on selkeästi myöhässä. Hänen mukaansa korjaavien toimenpiteiden aloittamisen automatisointi sekä selkeiden parametrien määrittäminen vähentää ihmisen oman havainnointikyvyn osuutta, mikä nopeuttaa korjaavien toimenpiteiden aloittamista ja lopulta vähentää kokonaismyöhästymää.

Joissain tapauksissa prosessin mukaan eteneminen ei ole riittävä toimi asiakastilauksen valmistumiselle ja silloin asiakas saattaa hyödyntää myös toimitusten nopeuttamista tai kiirehtimistä (engl. expediting) osittaisena ratkaisuna toimitusketjun epävarmuuksiin (Kouvelis & Tang, 2012).

Uudelleentyöstö

Uudelleentyöstö on valmistavan teollisuuden projektien tuotannossa usein esiintyvä vaihe, ja sillä tarkoitetaan jo tehdyn työn uudelleen tekemistä laadullisista (eli usein sisäisistä) syistä tai vaatimusten muutoksista (eli ulkoisista syistä) (Zhou, 2022). Uudelleentyöstön vaikutus asiakastilausten myöhästymään on merkittävä, sillä uudelleentyöstö ei lähtökohtaisesti kuulu tilaus-toimitusprosessiin, vaan usein valmistavan teollisuuden kontekstissa keskeneräinen tai valmis tuote ohjataan uudelleentyöstöön yllättävän muutoksen takia. Lyneis ja Ford (2007, 158) nostavat uudelleentyöstön ja tiukkojen aikatauluvaatimusten yhteyden artikkelissaan kuvaamalla projektia lineaariseksi, mutta uudelleentyöstöä silmukkamaiseksi, epätoivotuksi, mutta yllättävän usein myös tarpeelliseksi osaksi valmistusprosessia. Heidän mukaansa uudelleentyöstön riski nousee, mikäli aikataulupaine nousee. Muita sisäisien riskitason nousuun vaikuttavia tekijöitä ovat esimerkiksi uusien työntekijöiden aloittaminen, ennalta tuntemattomien materiaalien käyttäminen ja työkuorman sekä intensiteetin kasvu. Merkittävimmät ulkoiset tekijät ovat asiakkaan luoma aikataulupaine sekä asiakasvaatimusten muuttuminen, mikä voi johtua tarjousvaiheen heikosta toteuttamisesta tai asiakkaan oman tarpeen äkillisestä muutoksesta.

Ulkoinen aikataulupaine voi johtaa sisäisiin päätöksiin, jotka ovat jälkeenpäin tarkasteltuna heikkoja tai jopa epätoivoisia. Zhoun et al. (2022) mukaan uudelleentyöstö on yksi merkittävimmistä tekijöistä tilausten myöhästymiselle sekä kustannusten nousulle, ja Lyneisin ja Fordin (2007, 162) mukaan tapahtumista opittu tieto konkretisoituu liian harvoin korjaavina toimenpiteinä myöhemmissä projekteissa. Lyneisin ja Fordin (2007, 163) mukaan myös uudelleentyöstön kerrannaisvaikutukset ovat merkittäviä ja ne tulisi ottaa tosissaan. Esimerkki kerrannaisvaikutuksesta on se, että ihmisen tekemän virheen vuoksi tuote vaurioituu, mikä johtaa usein uuden materiaalin tilaamiseen. Tämä voi viivästyttää tilausta jopa kuukausia. Uudelleentyöstöprosessin aikana asiakkaiden vaatimukset voivat muuttua esimerkiksi uusien investointien myötä eikä alkuperäinen tilaus olekaan enää asiakkaan uusien vaatimusten mukainen. Zhoun et al. (2022) ja Lyneis ja Ford (2007, 163) mukaan merkittävin ja yksinkertaisin keino uudelleentyöstön vähentämiselle on varhaisen vaiheen testaaminen, jonka avulla laatuongelmat voidaan havaita mahdollisimman aikaisin. Muita käytännössä todettuja keinoja ovat toimitusaikataulupuskureiden ylläpitäminen, henkilöstön riittävä määrä, ylitöiden teettäminen mahdollisimman harvoin, projektin suunnittelu- ja tarjousvaiheen huolellinen sekä ammattitaitoinen toteuttaminen ja henkilökunnan ammattitaidon säännöllinen päivittäminen. (Graham et al., 2000; Lyneis & Ford, 2007)

Tehtaan kapasiteetti ja asiakastilausten priorisointi

Yksi valmistavan teollisuuden perustavanlaatuisista haasteista on asettaa koneiden kapasiteetti sekä käytössä olevan työvoiman määrä vastaamaan tulevaa kysyntää. Tilausohjautuvan tuotannon merkittävimpiin haasteisiin kuuluu lyhyen aikavälin kapasiteetin maksimointi (Tanrisever et al., 2012). Tuotantoa pyritään optimoimaan, jotta mahdollisimman moni asiakastilaus saataisiin valmiiksi ennalta määritetyn aikataulun mukaiseksi. Tuotantopäällikkö joutuu ottamaan huomioon saatavilla olevan työvoiman priorisoidessaan asiakastilauksia, jotta toiminta pysyisi mahdollisimman tuottavana. Saman aikaisesti pyritään tilanteeseen, jossa kapasiteettia hyödynnetään sen potentiaalin verran, mutta kuitenkaan ylittämättä sitä. Tämä johtaa väistämättä tilanteeseen, jossa tiettyjä asiakastilauksia joudutaan priorisoimaan, mikä puolestaan myöhästyttää priorisoimattomia tilauksia (Chen et al., 2009). Chen et al. (2009) pyrki matemaattisen mallinnuksen avulla tutkimaan, miten kapasiteettia voisi hyödyntää mahdollisimman tehokkaasti. Heidän mukaansa valmistavien yritysten tulee jo tilausten hyväksymisvaiheessa tunnistaa eri

tilausten vaikutukset tehtaan toimintojen käyttöasteeseen. Kun ”tilaus-mix” on asetettu optimaalisesti, tehtaan resurssien kokonaishyödyntämisaste nousi jopa 20 %-yksikköä. Tietyissä tapauksissa tämä ei ole mahdollista, johon Chen et al. (2009) suosittelee ylityön teettämistä ja alihankinnan hyödyntämistä. Hicks et al., (2000) kuitenkin muistuttaa, että alihankintakaan ei ole riskitön vaihtoehto vaan se voi aiheuttaa tilauksella myöhästymää, varsinkin jos valmistettavat tuotteet ovat monimutkaisia.

Pollock ja Richardson (2006) nostivat artikkelissaan esille tehtaiden työjonoille tarkoitetut suunnittelutyökalut, jotka ovat toki välttämättömiä tehokkaan tuotannon takaamiseksi, mutta ne eivät kuitenkaan usein pysty ottamaan täysin huomioon käytännön yksityiskohtia sekä monimutkaisia tehdasolosuhteita. Heidän mukaansa tehtaan suorituskyvyn reaaliaikainen seuranta on tarpeen, jotta resurssien tehokas priorisointi voidaan varmistaa. Tehtaiden tulisi seurata valmistuksessa olevia tuotteita, jotka syystä tai toisesta eivät etene tuotannossa. Nämä ongelmat tulisi tunnistaa ja tutkia, kuinka kauan mikäkin ongelma vaikuttaa, jotta ongelman aiheuttajiin voitaisiin puuttua tarkasti. Näitä ongelmia voivat olla esimerkiksi laitteiston huoltokatkot, tuotannon tehottomuus, tuotteeseen tehtävät suunnittelumuutokset, sekä tuotannon pullonkaulat.

Chen et al. (2012) nostivat artikkelissaan esille, että useita tavoitteita sisältävät aikataulut ovat yhä yleisempiä alati kilpailullisemmassa markkinassa. Tyypillisiä aikataulutavoitteita ovat olleet työkuorman tasapainoinen jakaminen koneiden käyttöasteen maksimoimiseksi, tuotannon läpimenoajan lyhentämiseksi ja luvattujen toimitusaikojen varmistamiseksi asiakkaille. Toisaalta valmistusyritysten on säilytettävä vahva markkina-asema kilpailluilla markkinoilla, mikä edellyttää asiakaslähtöistä tuotannon priorisointia. Akyildiz et al. (2015) tutkivat artikkelissaan asiakastilausten priorisointia valmistavissa yrityksissä, etenkin tilanteessa, jossa resurssit ovat rajalliset. Artikkelissa esitellään kriteeristö, joka auttaa yrityksiä hallitsemaan tilausten tärkeysjärjestystä tehokkaasti. Kyseisen terästeollisuuden case-yrityksen tapauksessa kirjallisuuteen pohjaten valittiin seuraavat priorisointikriteerit:

1. Mahdollinen voitto per aikayksikkö. (Wang et al., 1994)
2. Potentiaalisen tilauksen yhteensopivuus käytettävissä olevan kapasiteetin kanssa. (Balakrishnan et al, 1996; Patterson et al., 1997; Barut & Sridharan, 2005)
3. Potentiaalisen tulevan, korkeamman voiton tuovan tilauksen todennäköisyys. (Hung & Lee, 2010)
4. Asiakkaan maksukyky ja tulevaisuuden liiketoimintamahdollisuudet. (Wang et al., 1994)
5. Tilauksen tuotantoaikataulun neuvoteltavuus. (Wang et al., 1994)

Tutkimuksen ytimessä ei kuitenkaan ollut itse kriteeristön sisältö, vaan tarkoituksena oli tehdä tapaustutkimusyrityksen päätöksenteosta systemaattisempaa, sillä ihmiset ovat usein taipuvaisia pysymään mielipiteissään, vaikka uusia näkökulmia olisi saatavilla. (Akyildiz et al., 2015)

2.2 Eskalointijärjestelmän rooli tuotannon tehostamisessa

Tässä alaluvussa pyritään kartoittamaan mitä keinoja eräällä toisella tilausohjautuvan tuotannon parissa toimivalla yrityksellä on hallita toimitusketjun sekä tuotannon ongelmia. Valmistavan teollisuuden yhtiöt panostavat paljon resursseja toimintojensa suunnitteluun, mutta usein yrityksen kokonaisvaltainen suorituskyky riippuu pitkälti siitä, kuinka hyvin ne pystyvät toteuttamaan suunnitelmansa muuttuvissa olosuhteissa ja odottamattomien häiriöiden keskellä (Gödri, 2024). Monostori et al. (1998) nostaa muutosten, häiriöiden ja keskeytysten hallinnan keskeiseksi tekijäksi valmistavan teollisuuden menestyksessä. Kyberfyysisten tuotantojärjestelmien kehityksen myötä yrityksillä on laaja valikoima työkaluja ja tekniikoita, joilla voidaan arvioida suunnitellun ja toteutuneen tuotannon välistä poikkeamaa, lieventää sen vaikutuksia ja mukauttaa järjestelmän toimintaa muutosten äärellä (Monstori et al., 2016; Sahebjamnia et al., 2015).

István Gödri (2024) esittelee artikkelissaan, minkälaisen digitaalisen eskalointijärjestelmän korkean tuotekustomoinnin ja alhaisen volyymin teollisessa ympäristössä toimiva yritys on kehittänyt, mitä sen hyödyntämisestä on opittu ja mitkä sen vaikutukset ovat olleet viimeisen kuuden vuoden aikana. Yrityksen suurin motiivi kehittää digitaalinen eskalointijärjestelmä

oli se, että vaikka suunnitteluprosessit olisivat kuinka hyviä, tehtaan toiminta voi olla tehokasta yrityksen mukaan vain silloin, kun suunnitelmien toteutumista seurataan jatkuvasti, poikkeamat havaitaan ajoissa ja niihin reagoidaan mahdollisimman nopeasti. Tehokkaan eskalointijärjestelmän tulisi Gödrin (2024) mukaan täyttää seuraavat vaatimukset: 1. Mahdollistaa reaaliaikaisen tilanteen arvioinnin ja poikkeamien tunnistamisen sekä välittömien ratkaisujen tuottamista oikealla organisaatiotasolla. 2. Estää häiriöiden leviämistä monimutkaisessa tuotantoympäristössä. 3. Tallentaa kaikki eskalointitiedot järjestelmällisesti, jotta niitä voidaan analysoida ja hyödyntää toiminnan kehittämisessä.

Gödrin (2024) mukaan yrityksen tuotannon poikkeavuudet voitiin jakaa seitsemään kategoriaan, jotka olivat raakamateriaalin puute, koneistuksen ohjelmointiongelmat, laitteiden hajoaminen, informaatiokatkokset ja kommunikointiin liittyvät ongelmat, tuotantoteknologiaan liittyvät haasteet, laatuhaasteet ja muut haasteet, kuten työvoiman puute esimerkiksi sairastapauksen vuoksi.

Eskalointijärjestelmän käytännön toteutus alkaa tuotannon poikkeavuuden huomaamisesta, jolloin operaattori eskaloi ongelman oikealle asiantuntijalle e-tiketin avulla. Järjestelmä koostuu vähintään kolmesta tasosta: ensisijaisesta- ja toissijaisesta ratkaisuryhmästä sekä mahdollisesta ”Task force” -ryhmästä. Jos ensisijainen ratkaisuryhmä ei löydä vastausta ongelmaan ennalta määritettyjen aikarajojen puitteissa, ongelma siirretään toissijaiselle ratkaisuryhmälle. Jos toissijaisellakaan ratkaisuryhmällä ei ole ajoissa ratkaisua, eskalaatio siirtyy automaattisesti seuraavalle tasolle, jossa sitä käsittelee ”Task Force” -ryhmä. Käytännössä eskalointitasoja voi olla enemmän kuin kolme, ja niiden määrä on ennalta määritelty eskaloinnin kohteen ominaisuuksien perusteella. Task Force" -ryhmä koostuu asiantuntijoista, jotka edustavat tuotantoa, laatua, materiaalilogistiikkaa, toimitusketjun hallintaa, valmistustekniikkaa, tuotekehitystä ja suunnittelua, henkilöstöhallintoa sekä tietotekniikkaa. Ratkaisemattomien ongelmien käsittelyyn muodostetaan usein myös väliaikaisia tiimejä, joiden vetäjä tulee aina ongelman päävastuualueelta.

Eskalointijärjestelmän pääperiaate on se, että ratkaisujen etsintä aloitetaan alimmalta mahdolliselta eskalaatiotasolta (operaattori luo e-tiketin) ja se siirretään ylemmälle tasolle vasta, jos sopivaa ratkaisua ei löydy ennalta määritellyssä ajassa. Gödrin (2024) mukaan järjestelmän käytöstä seuranneet hyödyt olivat kuuden vuoden seurannan jälkeen seuraavat:

1. Poikkeamien reaaliaikainen seuranta ja hallinta mahdollistavat nopeamman reagoinnin. Aikaisemmin ongelma ratkaistiin alle kahdeksassa tunnissa 81 %:ssa tapauksista, uudistuksen jälkeen lukema on 95 %.
2. Ongelmat ohjataan suoraan oikealle ratkaisuryhmälle, mikä vähentää viiveitä ja parantaa tehokkuutta.
3. Ratkaisujen tehokkuuden mittaaminen on osoittanut, että järjestelmän käyttö on lyhentänyt sekä reagointiaikaa että ongelmien ratkaisuaikaa.
4. Järjestelmä tukee jatkuvaa kehitystä, sillä se tuottaa arvokasta dataa, jota voidaan hyödyntää päätöksenteossa ja prosessien parantamisessa.

Kaiken kaikkiaan järjestelmän käyttöönotto on parantanut tehtaan joustavuutta ja kykyä sopeutua tuotantohäiriöihin, mikä on erityisen tärkeää korkean tuotekustomoinnin ja alhaisen volyymin ympäristössä. Järjestelmän tuottamaa dataa voidaan hyödyntää sekä operatiivisessa päätöksenteossa että pitkän aikavälin kehitystyössä, minkä ansiosta tuotantoprosessin resilienssi on merkittävästi parantunut. (Gödri, 2024)

2.3 Tekoälyn määritelmä ja kehitys

Tekoälyllä ei ole tarkkaa määritelmää ja esimerkiksi Abbasin (2021) mukaan yksiselitteinen määritelmä on todella haastavaa muodostaa siten, että kaikki tekoälyn osa-alueet otettaisiin huomioon. Liebowitzin (2020) mukaan tekoälyllä tarkoitetaan ohjelmistojen ja laitteistojen tutkimusta ja kehitystä, joiden tavoitteena on jäljitellä ihmisen toimintaa. Myös Haenleinin ja Kaplanin määritelmään on viitattu erilaisissa julkaisuissa. Haenlein ja Kaplan (2019, 1) määrittelevät tekoälyn seuraavasti: *”järjestelmän kyky tulkita ulkoista dataa oikein, oppia kyseisestä datasta ja hyödyntää oppimaansa saavuttaakseen tiettyjä tavoitteita ja tehtäviä joustavien sopeutumisten avulla.”* Usein tekoälyllä kuitenkin tarkoitetaan koneen kykyä käyttää perinteisesti ihmisen älyyn liitettyjä taitoja, kuten päättelyä, oppimista, suunnittelemista tai luomista (European parliament, 2020; Abbas, 2021; Zhou, 2018). Tekoälyn alakäsitteitä ovat esimerkiksi koneoppiminen (engl. Machine learning) sekä inhimillisen aivotoiminnan inspiroimat lähestymistavat, kuten esimerkiksi neuroverkot (engl. Neural networks) ja syväoppiminen (engl. Deep learning). Sekä syväoppiminen että koneoppiminen tarjoavat usein hyödynnettyjä työkaluja järjestelmien kehittämiseen, jotka

voivat oppia datasta, sopeutua uusiin tilanteisiin ja suorittaa ihmismäisiä tehtäviä yhä tarkemmin. (Mishra, 2023). Edellä mainittujen käsitteiden välisiä suhteita ja päällekkäisyyksiä on havainnollistettu Kuvassa 3.

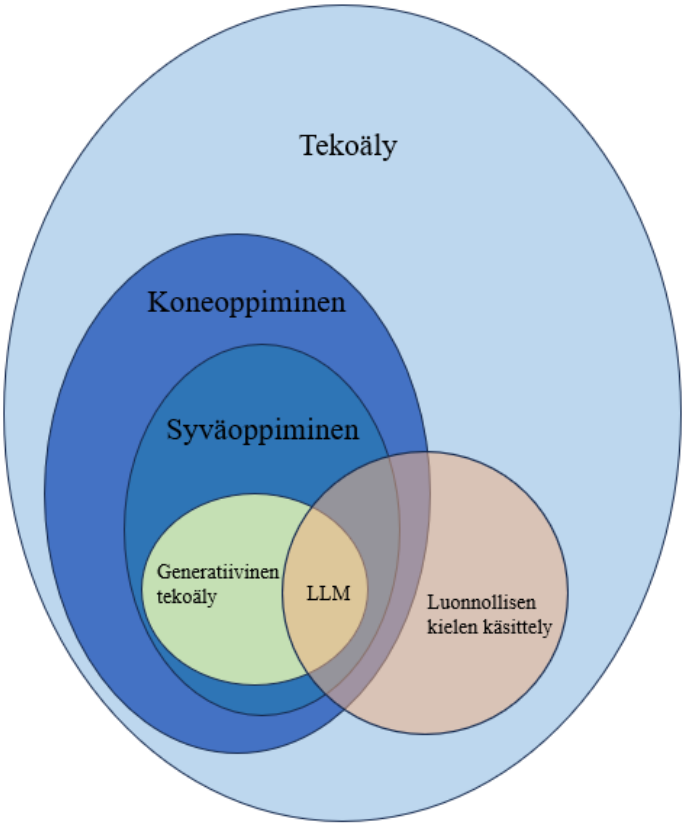

Kuva 3. Tekoälyn konseptit (mukaillen Amaratunga, 2023, 7)

Tekoäly mahdollistaa älykkäiden sovellusten hyödyntämisen erilaisissa koneissa ja järjestelmissä. Kehitystä on osin inspiroinut neurotieteellinen tutkimus, erityisesti aivojen rakenteiden ja toimintojen ymmärtäminen, mutta nykyiset tekoälyratkaisut, kuten koneoppiminen, perustuvat pääasiassa matemaattisiin ja tilastollisiin menetelmiin. Koneoppimisella viitataan yleisesti menetelmiin, joiden avulla järjestelmät voivat oppia ratkaisemaan ongelmia kokemukseen tai dataan perustuen ilman ennalta ohjelmoituja sääntöjä (Zhou et al., 2018, 267–268). Koneoppiminen on prosessi, jossa automatisoitu järjestelmä käyttää aiemmista kokemuksista saatuja tietoja tehdäkseen ennusteita tulevaisuudesta ja sitä kautta parantaakseen suorituskykyään (Zhou et al., 2018, 267–268). Yleensä tämä oppimisprosessi koostuu kahdesta osasta, koulutuksesta ja ennustamisesta (engl. interference). Koulutusvaiheessa malli yrittää oppia sille asetetut tavoitteet, ja ennustusvaiheessa se tekee varsinaiset ennusteet. Zhou et al. (2018, 267–268) mukaan

koneoppimisen algoritmit voidaan jakaa kolmeen kategoriaan: ohjattuun oppimiseen, ohjaamattomaan oppimiseen sekä vahvistusoppimiseen. Ohjatussa oppimisessa algoritmi oppii ennustamaan tai luokittelemaan dataa käyttämällä valmiiksi merkattua opetusaineistoa. Ohjaamattomassa oppimisessa algoritmi analysoi dataa itsenäisesti ja pyrkii löytämään rakenteita, kuten klustereita tai yhteyksiä, ilman valmiiksi annettuja tavoitearvoja. Vahvistusoppimisessa algoritmi toimii vuorovaikutuksessa ympäristön kanssa ja oppii tekemällä päätöksiä sekä saamalla niistä palautetta palkkioiden tai rangaistusten muodossa.

Tekoälyn tutkimus kehittyy jatkuvasti ja tarjoaa dynaamisia mahdollisuuksia uudistaa tapoja, joilla vuorovaikutamme teknologian kanssa ja ymmärrämme älykkyyttä. Tällä hetkellä tekoälyteknologioiden käyttöönotto on keskeistä kilpailuedun ylläpitämiseksi useilla toimialoilla, kuten sosiaali- ja terveydenhuollossa, valmistavassa teollisuudessa ja kuluttajatuotteissa (Chowdhary 2020, 10). Tämä diplomityö keskittyy erityisesti tekoälyn hyödyntämiseen tekstin analysoimisessa ja siihen, kuinka yritykset voivat hyödyntää näitä uusia teknologioita, joten syväoppimisen tai koneoppimisen toimintaperiaatteisiin ei syvennytä tarkemmin.

Teknologiset läpimurrot suurten kielimallien (engl. Large language models) parissa ovat luoneet viime aikoina uusia mahdollisuuksia hyödyntää tekoälyä niin yksilön kuin yhteiskunnan tasolla, ja potentiaalia on myös taloudellisen lisäarvon luomiseen. Generatiivinen tekoäly on tekoälyn osa-alue, joka keskittyy luomaan uutta sisältöä olemassa olevan tiedon pohjalta (Taulli, 2023). Useat generatiivisen tekoälyn sovellukset perustuvat suuriin kielimalleihin, jotka tulivat suuren yleisön tietoisuuteen vuonna 2022, kun OpenAI julkaisi GPT-3.5-kielimallin, joka oli edeltäjiään selkeästi parempi käsittelemään kielen monimutkaisempia piirteitä sekä tuottamaan tarkempia vastauksia (OpenAI, 2024; Laaksonen, 2023). ChatGPT:n lisäksi muita esimerkkejä generatiivisista tekoälyjärjestelmistä ovat muun muassa GAN-verkot (engl. Generative adversarial networks) sekä diffuusiomallit, joita voidaan käyttää realististen kuvien luomiseen. ChatGPT:n kaltaisia suuriin kielimalleihin perustuvia ”chatbot”-sovelluksia ohjataan pääosin kehotteilla, jotka ovat usein muutaman lauseen ohjeistuksia, joissa kuvataan haluttua lopputulosta mahdollisimman tarkasti. (Taulli, 2023)

Generatiivinen tekoälyllä on monia eri käyttötarkoituksia, kuten tekstin, kuvien ja 3D-mallien luomisen. Sen avulla voidaan myös tuottaa ja muokata ääntä sekä säveltää

musiikkia. Suurin läpimurto on kuitenkin tapa, jolla tämän teknologian kanssa ollaan vuorovaikutuksessa. Aiemmin tekoälyn hyödyntäminen edellytti ohjelmointitaitoja, mutta nyt kuka tahansa voi käyttää sitä luonnollisen kielen avulla keskustellen. (Laaksonen, 2023)

2.4 Luonnollisen kielen käsittelystä suurien kielimallien läpimurtoon

Tietojenkäsittelytieteissä luonnollisen kielen käsittely (engl. Natural language processing) on keskeinen tutkimusalue, joka keskittyy vuorovaikutuksen kehittämiseen koneiden ja ihmiskielen välillä (Kamath et al., 2024). NLP:n tavoitteena on kehittää algoritmeja ja tekniikoita, jotka mahdollistavat tietokoneiden ihmiskielen ymmärtämisen, tulkinnan ja tuottamisen. Perinteisesti NLP-menetelmät ovat perustuneet kielitieteelliseen lähestymistapaan, jossa kieltä analysoidaan esimerkiksi sanaluokkien kautta. Nykyiset syväoppimismenetelmät ovat kuitenkin vähentäneet tällaisten väliportaiden tarvetta, mikä on nopeuttanut NLP:n kehitystä (Kamath et al., 2024).

Luonnollisen kielen käsittely mahdollistaa esimerkiksi puheentunnistuksen ja kysymyksiin vastaamisen useilla eri kielillä. Näiden toteuttamiseksi NLP hyödyntää etenkin tokenisointia, jäsentelyä sekä upotuksia parhaimman lopputuloksen saavuttamiseksi. Tokenisointi pilkkoo tekstit pienempiin yksiköihin, joita kutsutaan tokeneiksi. Tokenisointi on olennainen esikäsittelyvaihe useimmissa NLP-tehtävissä. (Zhao et al., 2023) Tokenisoinnin lisäksi sanojen ja lauseiden välisiä suhteita analysoidessa tarvitaan jäsennystä (engl. parsing) (Amaratunga 2023, 17–19). Upotukset (engl. embeddings) ovat sanojen jatkuvia vektoriedustuksia, joissa merkitykseltään samankaltaiset sanat tai lauseet sijoittuvat lähelle toisiaan. Ne ilmentävät sanojen välisiä merkityksellisiä suhteita, mikä auttaa NLP-malleja tunnistamaan sanojen samankaltaisuuden ja asiayhteyden. Upotukset ovat keskeinen osa suuria kielimalleja, sillä ne mahdollistavat kielen vivahteiden ymmärtämisen ja esittämisen. Jotta suuret kielimallit voivat käsitellä ja tuottaa luonnollista kieltä, tarvitaan usein vektorimuotoista esitystä. (Amaratunga 2023, 19–21)

Suuret kielimallit ovat yksi luonnollisen kielen käsittelyn sovellus ja nämä mallit on suunniteltu hallitsemaan kielen monimutkaisuutta oppimalla valtavista määristä erilaista tekstiaineistoa (Eloundou et al., 2023, 4; Kamath et al., 2024). Suuret kielimallit soveltuvat moniin käyttötarkoituksiin, kuten tekstin tiivistämiseen, luokitteluun ja tuottamiseen. Ne tunnistavat monimutkaisia kaavoja datassa ja hyödyntävät näitä löydöksiä tuottaakseen

kontekstiin sopivia vastauksia (Devanny et al., 2023; Eloundou et al., 2023, 4). Devanny et al. (2023) uskoo myös, että tulevaisuudessa näitä suuria kielimalleja voidaan käyttää entistä monimutkaisempiin käyttötarkoituksiin.

Suurin osa suurten kielimallien ominaisuuksista on seurausta esikoulutusprosessista. Yksinkertaistettuna prosessissa käydään läpi esikoulutusdata, verkkoarkkitehtuuri ja oppimistavoitteet. Esikoulutusdata ei yleensä poikkea merkittävästi eri mallien välillä, vaan se koostuu usein verkkosivujen haravoinnista ja koodista, joka parantaa mallin päättelykykyä. Yleisesti ottaen esikoulutuksen pääasiallinen oppimistavoite on maksimoida luonnollisen kielen ymmärrys ja luoda johdonmukaisia generatiivisia kykyjä. (Kamath et al., 2024, 16)

Kuvassa 4 esitellään polku, jolla käsillä olevaa ongelmaa voidaan lähteä ratkaisemaan kielimallien avulla. Esikoulutettuja suuria kielimalleja kutsutaan usein perusmalleiksi (engl. foundation model), koska ne on koulutettu laajamittaisesti erilaisilla yleispätevillä tietoaineistoilla ja ne pystyvät suoriutumaan hyvin monentyyppisistä tehtävistä, jotka eivät vaadi tarkempaa koulutusta (Bommasani et al., 2021; Naveed et al., 2023). Erikoistuneiden sovellusten tarpeisiin tarvitaan kuitenkin koulutusta, joka vastaa paremmin juuri kyseisen sovelluksen vaatimuksia. Tämä koulutus voidaan toteuttaa erilaisilla hienosäätömenetelmillä. Sen sijaan, että luotaisiin täysin uusi malli kyseiseen käyttötarkoitukseen, perusmallia voidaan mukauttaa jatkokoulutuksella käyttäen erilaisia tekniikoita.

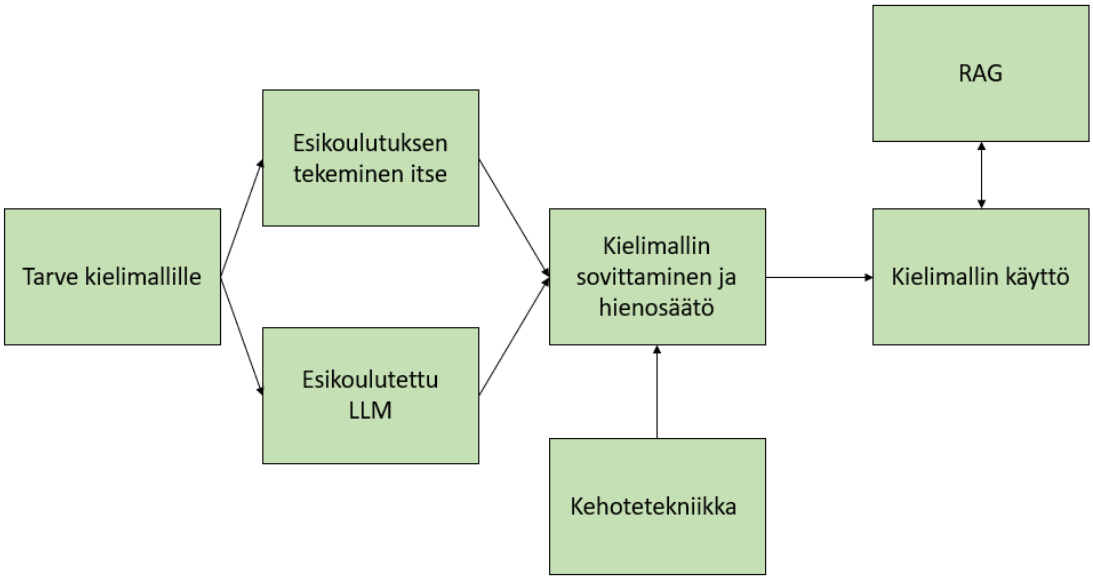

Kuva 4. Huomioon otettavien polkujen yksinkertaistettu kuvaus kielimallia kehittäessä (mukaillen Kamath et al., 2024)

Raskain hienosäätämisen muoto on kaikkien parametrien muokkaaminen (engl. Full parameter fine-tuning). Tämä ei kuitenkaan ole useille toimijoille mahdollinen tapa kouluttaa kielimallia sen resursseja vaativan luonteen vuoksi. Kehitys on johtanut parametritehokkaampaan hienosäätöön, jossa minimoidaan muokattavien parametrien määrää. Kehityspolun loppupuolella loppukäyttäjällä on vielä mahdollisuus hienosäätää kielimallia kontekstiin sidotulla oppimisella. Kielimallin suoriutumista voidaan ohjata esimerkkien avulla syöttämällä tehtävä sille kontekstissa joko nollanäytteellä (engl. zero-shot), vähillä näytteillä (engl. few-shot) tai monilla näytteillä (engl. multi-shot). Näissä menetelmissä mallin painoarvoja ei kouluteta uudelleen, vaan se hyödyntää sille annetut esimerkit väliaikaisesti ratkaistakseen annetun tehtävän. (Mukhoti et al., 2023; Kamath et al., 2024, 18–20). Kielimallin hienosäätäminen ja etenkin kontekstiin sidottu oppiminen on useille toimijoille ainoa relevantti tapa saavuttaa halutunlainen kielimalli, sillä suurien kielimallien luominen alusta alkaen vaatii valtavasti resursseja, kuten rahaa, osaamista sekä aikaa. (Kamath et al., 2024, 18–20)

Esikouluttamisen ja hienosäädön jälkeen kielimalli pystyy vastaamaan useimpiin, jopa tarkkoihin ja kontekstiriippuvaisiin kysymyksiin erinomaisesti, mutta kielimallin vastausten laatua voidaan parantaa vielä entisestään RAG:n avulla (engl. Retrieval-augmented

generation) kielimallin käyttövaiheessa (Zhao et al., 2023, 4445–4448). Myös esimerkiksi Gao et al. (2024) pitää RAG-menetelmää tehokkaana ratkaisuna mm. hallusinointiin, vanhentuneeseen tietoon tukeutumiseen, ja peiteltyyn tai muuten hankalakulkuisen vastauksenmuodostusprosessin parantamiseen. RAG:n perimmäinen tarkoitus on etsiä vastauksia kysymyksiin esimerkiksi erilaisista tietokannoista tai asiakirjoista, jotka perustuvat ajankohtaiseen, kontekstiin sidottuun ja tarkkaan tietoon. Tämän prosessin avulla kielimallin vastauksista saadaan laadukkaampia ilman raskaampaa lisäkoulutusta. RAG-menetelmä on todettu erityisen toimivaksi tilanteissa, joissa kysymyksille on olemassa hyvin määriteltyjä vastauksia tai kun halutaan, että malli pohjaa vastauksensa tiettyyn ennalta määriteltyyn aineistoon, joka on poikkeuksellisen kontekstisidonnainen. Kielimallin vastaukset riippuvat suuresti aineiston laadusta, joten sisällön tulee olla tarkasti laadittua ja kattavaa. (Gao et al., 2024, 1)

Kuvassa 5 esitettynä yksinkertaistettuna RAG-prosessi. Gao et al. (2024) esittelee artikkelissaan naiivin RAG-prosessin soveltaminen kysymysten vastaamiseen, joka koostuu pääosin kolmesta vaiheesta:

1) Indeksointi, eli dokumentit jaetaan osakokonaisuuksiksi, koodataan vektoreiksi ja tallennetaan vektorikantaan.

2) Hakeminen (engl. Retrieval). Etsitään kysymykseen semanttisen samankaltaisuuden perusteella parhaiten liittyvät Top k-osakokonaisuudet. Top-k-parametrin käyttö yksinkertaistettuna poistaa useita pienen todennäköisyyden omaavia sanoja.

3) Generointi. Syötetään alkuperäinen kysymys ja haetut osat yhdessä suureen kielimalliin, joka tuottaa lopullisen vastauksen uuden lähdemateriaalin perusteella.

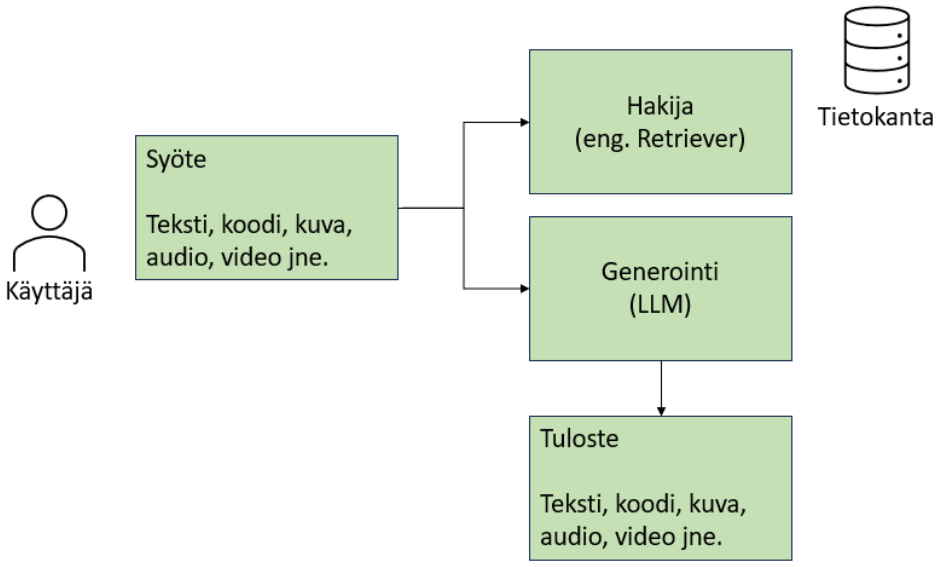

Kuva 5. Geneerinen RAG integroituna kielimalliin (mukaillen Arslan et al., 2024)

Naiivi RAG oli ensimmäinen kyseiseen tekniikkaan liittyvä metodologia. Kehittyneempiä RAG:n muotoja ovat kehittynyt RAG sekä edelleen sen pohjalta kehitetty modulaarinen RAG, jotka pyrkivät ratkaisemaan haasteita, joita on huomattu aikaisempien tekniikoiden käyttämisessä. Nämä haasteet voidaan Gaon et al. (2024) mukaan jakaa kolmeen osaan, jotka esitellään seuraavaksi.

Hakuvaiheen haasteet. Hakuvaiheessa on usein ongelmia tarkkuuden ja kattavuuden kanssa, mikä voi johtaa siihen, että valitaan epäolennaisia tai virheellisesti kohdistettuja osia ja samalla ohitetaan keskeistä tietoa.

Generointivaiheen vaikeudet. Vastausten generoinnissa malli voi alkaa hallusinoimaan, jossa se tuottaa sisältöä, joka ei perustu haettuun kontekstiin. Lisäksi generointi voi kärsiä epäolennaisuudesta, haitallisista tai puolueellisista sisällöistä, jotka heikentävät vastausten laatua ja luotettavuutta.

Augmentoinnin haasteet. Haetun tiedon yhdistäminen eri tehtäviin voi olla haastavaa, mikä voi johtaa katkonaisiin tai epäjohdonmukaisiin vastauksiin. Prosessi voi myös kohdata päällekkäisyyttä, kun samankaltaista tietoa haetaan useista lähteistä, mikä johtaa toistuviin vastauksiin. Monien osien merkityksen ja relevanssin arviointi sekä tyylin ja sävyn johdonmukaisuuden varmistaminen lisäävät prosessin monimutkaisuutta.

Monimutkaisia ongelmia kohdatessa alkuperäiseen kyselyyn perustuva yksittäinen haku ei välttämättä riitä hankkimaan riittävää kontekstia. Lisäksi on huoli siitä, että generointimallit saattavat liikaa tukeutua laajennettuun tietoon, mikä johtaa vastauksiin, jotka vain toistavat haettua sisältöä ilman merkittäviä oivalluksia tai yhdistelyä. Arslan et al. (2024) tutkivat artikkelissaan yritysten digitaalisen murroksen edistystä tiedon erottelussa. Heidän tapaustutkimuksessaan huomattiin huomattavia etuja aikaisemmin manuaalisesti analysoitavan datan läpikäymisessä. Suuret kielimallit, joita parannetaan RAG-menetelmällä, tuottivat tarkkoja lopputuloksia murto-osassa aikaa. Heidän mielestään yritysten tulisi panostaa T&K-toimintaan tällä saralla, jotta potentiaaliset hyödyt saataisiin skaalattua koko yrityksen laajuudelle. He kuitenkin muistuttavat, että tutkimuksessa kehitetty konseptitodistus omaa joitain rajoitteita. Potentiaaliseksi ongelmaksi koettiin esimerkiksi käyttäjän turvautuminen vain kielimallin tekemiin yhteenvetoihin. Tämä voi johtaa erilaisten kokonaisuudelle tärkeiden yksityiskohtien hukkaamiseen, ja täten päätösten heikentymiseen. Myös Gao et al. (2024) havaitsivat Arsalnin et al. (2024) samantyylisiä ongelmia omassa tutkimuksessaan

2.5 Suurien kielimallien hyödyntäminen tekstianalyysin tukena

Suurien kielimallien mahdollisuudet on noteerattu myös vapaamuotoisen tekstin analysoimisessa. Vapaamuotoista tekstiä on tähän asti analysoitu pääosin manuaalisesti, minkä on koettu olevan vaivalloista, hidasta sekä kallista. Manuaalisen analyysin heikkoutena voidaan pitää myös analysoijan omia mielipiteitä, jotka saattavat vaikuttaa analyysin objektiivisuuteen. Aikaisemmin koneoppimismallit ovat pystyneet analysoimaan yksinkertaisia tekstejä, jotka käsittelevät jotain tarkkaan määritettyä aihetta, mutta monikielisessä sekä vaihtuvan kontekstin ympäristössä koneoppimismallit eivät pärjää manuaaliselle analyysille. Nyt tähän ongelmaan on mahdollisesti saatavilla ratkaisu suurien kielimallien yleistyessä. Suuria kielimalleja pidetään helppokäyttöisinä, suhteellisen edullisina, sekä nopeina keinoina analysoida tekstiä. (Törnberg, 2023)

Perinteiset koneoppimiseen perustuneet mallit eivät ole aikaisemmin voineet analysoida tekstiä ilman esikäsittelyä. Suuret kielimallit voivat puolestaan lukea prosessoimatonta ja sekalaista dataa, usealla eri kielellä samanaikaisesti, joten dataa ei välttämättä tarvitse esikäsitellä. Lopputuloksen kannalta suurin tekijä kielimallin hienosäätämisen jälkeen on

itse kehotteen hiominen. Kielimallien, kuten ChatGPT:n kouluttamisessa voidaan hyödyntää kehotetekniikkaa (engl. prompt engineering), joka on kontekstissa oppimisen käytännönläheinen muoto. Tässä tekniikassa pohditaan tapoja, joilla varsinainen kysymys muotoillaan täsmällisesti, ja tarjotaan kielimallille vielä lisäkontekstia sekä ohjeita tai esimerkkejä, miltä haluttu lopputulos mahdollisesti näyttäisi käyttäjän näkökulmasta. (Sahoo et al., 2024; Viswanath, 2024). Tämä on yksinkertainen ja kevyt tapa ohjata mallin toimintaa, sillä se ei vaadi lainkaan mallin parametrien muokkaamista, vaan hyödyntää ainoastaan olemassa olevia tietoja ja mallin ennakoivaa kyvykkyyttä.

Kaushik Viswanath (2024) nostaa artikkelissaan kolme seikkaa, jotka kannattaa huomioida kehotetta luodessaan, jos haluaa parhaan mahdollisen lopputuloksen. Ensimmäinen huomio on: "ole kohtelias". Viswanathin mukaan kohtelias käytös parantaa kielimallin vastausta merkittävästi, kun taas tyly lähestyminen heikentää tuloksia. Tämä ominaisuus johtuu todennäköisesti suurien kielimallien koulutusdatasta, jossa ihmiset ovat vuorovaikutuksessa keskenään, ja kohtelias käytös edistää halutun lopputuloksen saavuttamista myös tosielämässä. Toinen huomioon otettava yksityiskohta on kontekstin antaminen. Suurien kielimallien yksi merkittävin heikkous on hallusinointi eli vastausten vääristely ja ”satuilu”, johon syvennytään seuraavassa alaluvussa. Kontekstin lisääminen kehotukseen pienentää hallusinointia, sillä suuri kielimalli voi suoraviivaistaa vastauksenmuodostamisprosessiaan, mikä puolestaan vähentää virheellisiä tulkintoja. Kolmas seikka parempien lopputulosten saavuttamiseksi on antaa aina kielimallille rooli, joka antaa kielimallille näkökulman, josta se lähtee työstämään vastaustaan.

Petter Törnbergin (2023) mukaan laadukkaan kehotteen tulee puolestaan 1. Määrittää tehtävä, 2. Määrittää haluttu lopputulos, 3. Olla riittävän tarkka, 4. Sisältää ohjeistus ja tarkka konteksti. Lopuksi näiden kohtien jälkeen yleensä tarvitaan useampi iteraatio, jotta lopputulos olisi mahdollisimman hyvä. Lopputulosten validointi on tärkeä osa analysointiprosessia. Tämä voidaan tehdä esimerkiksi seuraavasti: poimitaan kohdedatasta pieni otos manuaaliseen tarkasteluun ja vertaillaan tuloksia ihmisen ja kielimallin välillä. (Törnberg, 2023)

Kehotetekniikasta on muodostunut merkittävä tutkimusalue erityisesti sen tehokkuuden ansiosta nykyaikaisten suurten kielimallien hyödyntämisessä. Kehotetekniikan kehittyneempiä muotoja ovat esimerkiksi ajatusketjumenetelmä (engl. Chain of thought), jossa tehtävä jaetaan loogisiksi osavaiheiksi päättelyn tukemiseksi, sekä generoitu tieto -

lähestymistapa (engl. Generated knowledge), jossa kielimalli tuottaa ja hyödyntää omaa taustatietoaan kehotteen täydentämiseksi. Näiden menetelmien on havaittu parantavan ongelmanratkaisun loogisuutta ja tehokkuutta sekä vähentävän hallusinaatioiden esiintymistä. (Chen et al., 2023; Sahoo et al., 2024; Kamath et al., 2024, 21; Zhang et al., 2024, 95).

2.6 Suurien kielimallien haasteet

Generatiivinen tekoäly on luonut lyhyessä ajassa yrityksille lukemattomia uusia mahdollisuuksia tehostaa toimintaansa. Organisaatiot ovat kohdanneet tai kohtaamassa isoja muutoksia tekoälyn saapuessa osaksi jokapäiväistä yritysmaailmaa. Potentiaalisten hyötyjen lisäksi generatiivisella tekoälyllä on myös mahdollisia haittavaikutuksia sekä haasteita.

Yksi generatiiviseen tekoälyyn pohjautuvien sovellusten suurimmista haasteista liittyy jo aiemmin sivuttuun hallusinointiin (Shen et al., 2023; Martino et al., 2023). Tekoälyhallusinaatioilla tarkoitetaan tilanteita, joissa esimerkiksi kielimalli tai kuvanluontijärjestelmä tuottaa tuloksia, jotka eivät perustu syöttötietoihin tai vastaa todellisuutta (Verspoor, 2024; Chang et al., 2024, 96). Tämä ilmiö voi olla erityisen ongelmallinen sovelluksissa, joissa tarkkuus ja luotettavuus ovat kriittisiä. Hallusinaatiot ovet yleinen ongelma suurien kielimallien, kuten OpenAI:n GPT:n eri kehitysversioiden yhteydessä, vaikka kehittyneemmät kielimallit ovat olleet aina edeltäjiään parempia taistelemaan hallusinaatioita vastaan (OpenAI, 2025). Nämä mallit voivat tuottaa sisällöltään yhtenäisiä ja vakuuttavia vastauksia, jotka ovat kuitenkin virheellisiä. (Verspoor, 2024; Martino et al., 2023) Hallusinaatioiden taustalla olevien syiden ja toimintamekanismien ymmärtäminen on ratkaisevan tärkeää tekoälymallien luotettavuuden kehittämisessä.

Suuret kielimallit hallusinoivat Martinon et al. (2023) mukaan siitä syystä, että kielimallin koulutusdata ei ikinä voi olla täydellistä, sillä tietoa on niin valtava määrä tarjolla sekä kaiken tiedon koodaus mallin parametreihin on haastavaa. Edellä mainitut seikat luovat lähtökohdat hallusinoinnille ja Zheng et al. (2023) jakaa nämä kielimallien, kuten ChatGPT:n hallusinointiongelmat neljään eri kategoriaan:

1. Ymmärrysvirhe. Kielimalli ymmärtää kysymyksen kontekstin tai tarkoituksen väärin ja antaa täten oudon vastauksen.
2. Asiavirhe. Kielimalli ymmärtää kysymyksen oikein, mutta jostain syystä vastaus esitetään uskottavasti väärin. Kyse voi olla esimerkiksi mallin puutteellisesta koulutuksesta.
3. Täsmällisyysvirhe. Kielimalli vastaa kysymykseen osittain oikein, mutta voi esimerkiksi sekoittaa joitain yksityiskohtia. Kyse voi olla myös, että kielimallin vastaus on liian tarkka tai liian laaja.
4. Päättelyvirhe (engl. Interference error). Kielimallilla on hallussaan kaikki oikeaan ratkaisuun vaadittavat tiedot, mutta se epäonnistuu yhdistämään ne ja lopputuloksena tuottaa väärän tuloksen, vaikka vastauksen perustelut olisivat oikeita.

Zheng et al. (2023) tutkimuksen mukaan lähes puolet kielimalliin perustuvan ChatGPT:n hallusinointiongelmista liittyi tosiasioiden muunteluun eli vastaus ei perustunut ns. faktatietoon. Zhengin et al. (2023) tutkimus keskittyi pääosin tosiasiavirheiden käsittelyyn, koska he kokivat tämän olevan kriittisin mallin toimivuuden kannalta. Tutkimuksessaan he pyrkivät löytämään keinoja, joilla kielimallin vastauksista tulisi laadukkaampia. Heidän mukaansa tehokkaimmat menetelmät perustuvat kontekstin antamiseen sekä muistuttamiseen, mikä tarkoittaa, että kehotteissa tuodaan esiin ne kokonaisuudet, joihin tehtävä viittaa. Kontekstin tulisi olla selkeästi määritelty ja mahdollisimman yksiselitteinen sekä yksityiskohtainen. Kuvaus käsiteltävästä kokonaisuudesta tulisi olla niin ikään mahdollisimman yksityiskohtainen, jotta kielimallin ei tarvitsi täyttää puuttuvia yksityiskohtia omilla tulkinnoillaan. Useat tutkijat ovat todenneet myös edellisessä alaluvussa käsitellyn RAG:n auttavan virheellisten sekä puutteellisten vastausten minimoimisessa (Arslan et al., 2024; Gao et al., 2024).

Suuriin kielimalleihin liittyy myös haasteita kyberturvallisuuden alueella. Yksi suurimmista haasteista kyberturvallisuudessa on varmistaa, että kyberhyökkäyksiä vastaan taistelevat puolustusjärjestelmät pysyvät kehityksessä mukana. Uusien teknologioiden kehittyminen, kuten suurien kielimallien laajamittainen käyttöönotto yksityishenkilöille ja yrityksille, avaa mahdollisuuksia uudenlaisten uhkien hyväksikäyttämiselle kyberturvallisuuden näkökulmasta. (Kucharavy et al., 2024)

Yksi suurien kielimallien isoimmista ongelmista tietoturvaan liittyen johtuu näiden suurien kielimallien perusperiaatteista. Varsinkin kielimallien koulutuksen loppuvaiheilla pyritään käyttämään mahdollisimman tarkkaa koulutusdataa, jotta kielimalli sopisi mahdollisimman hyvin vaadittuun käyttötarkoitukseen. Kielimalli muistaa koulutusdatansa, joten jos arkaluontoista tietoa joutuu kielimallien koulutusdataan, muodostuu siitä tietoturvariski. Vuodetun tiedon ensisijainen lähde on suurten kielimallien harjoitusaineisto. Tämä voi olla mallin koulutukseen käytetty datakokonaisuus, yksityinen tietoaineisto tai aineisto, joka on kerätty ihmispalautteeseen perustuvan vahvistusoppimisen avulla, jota on käytetty mallin hienosäätöön (Dwivedi, 2023; Sedkaoui & Benaichouba, 2024).

Tietoja voi vuotaa missä tahansa muodossa, kuten tekstinä, kuvina ja videoina, ääninä, monimuotoisena datana tai taiteellisina tyyleinä. Tekstiaineistossa vuotanut tieto voi sisältää sekä henkilötietoja, kuten puhelinnumeroita, osoitteita, luottokorttitietoja ja nimiä, että laajempia tekstiosioita, esimerkiksi yksittäisiä ohjelmistokoodin rivejä, funktiomäärittelyitä sekä kokonaisia ohjelmistoja. Kuvien osalta tiedon vuoto voi ulottua täsmällisestä toistosta luotujen ja toistettujen kuvien yhdistelmiin, ja vuotojen tunnistaminen voi olla haastavaa. Tietoja on myös yritetty kaivaa suurista kielimalleista erilaisilla kehotteilla, joiden tarkoituksena on muokata kielimallin vastausta siten, että se luovuttaisi arkaluontoista tietoa, jota se on saanut haltuunsa koulutusdatassaan (Bender, 2021; Kucharavy et al., 2024).

Kucharavyn et al. (2024) mukaan suurien kielimallien tietovuotoriskin arviointi on vasta alkutekijöissään. Kielimallien jatkuva kasvu ja sovellusten lisääntyvä monimutkaisuus tekevät arvioinnista entistä haastavampaa ja edellyttävät lisää tutkimusta. Suurien kielimallien kykyjen lisääntyminen ja ihmistasoisen suorituskyvyn saavuttaminen avaavat myös uusia tapoja aiheuttaa tietovuotoja, ja on yhä epäselvää, kuinka monta menetelmää on edelleen havaitsematta.

Generatiivisen tekoälyn mukana on myös huomattu olevan eettisiä haasteita. Sedkaoui ja Benaichouba (2024) keräsivät artikkeliinsa yleisimpiä generatiivisen tekoälyn mukanaan tuomia eettisiä haasteita. He ovat tunnistaneet useita eettisiä huolia, kuten sen että GAN-teknologiaa hyödyntävät työkalut voivat osaltaan vaikuttaa disinformaation leviämiseen. GAN-teknologialla voi tuottaa realistisen tuntuista audio- sekä kuvasisältöä, jossa alkuperäistä kuvaa tai ääntä on manipuloitu huomattavasti (Wach et al., 2023). Sedkaoui ja Benaichouba (2024) peräänkuuluttavat kehittäjien vastuuta toimia eettisesti sekä myös lainsäädännön roolia, jota tulisi päivittää mahdollisimman nopeasti uusien teknologioiden

yleistyessä. Toinen Sedkaouin ja Benaichouban (2024) nostama uhka työpaikkojen korvaantuminen tekoälyllä. Tekoälyn avulla on jo nyt voitu automatisoida useita yksinkertaisia työtehtäviä, mikä seurauksia useita työpaikkoja on jäänyt tarpeettomaksi. Ongelmaan esitetty ratkaisu sisältäisi esimerkiksi olemassa olevien työntekijöiden uudelleenkouluttamista vaativampiin työtehtäviin (Felten et al., 2023).

Myös kielimallien koulutuksesta voi seurata eettisiä ongelmia. Kielimallit omaksuvat käyttäjiensä kieltä ja esimerkiksi Bender (2021) nostaa esille, että etuoikeutetussa asemassa olevat ihmiset suhteessa yhteiskunnan rasismiin, misogyniaan sekä ableismiin ovat yliedustettuina kielimallien koulutusdatassa, tämä koulutusdata sisältää siten koodattuja ennakkoluuloja, joista monet on jo tunnistettu haitallisiksi.

2.7 Kielimallien soveltaminen teollisessa ympäristössä

Tässä alaluvussa perehdytään mahdollisiin sovelluksiin, joissa suuria kielimalleja on hyödynnetty teollisessa ympäristössä. Keskittymiskohtana on erityisesti kielimallin kyky tunnistaa teollinen konteksti ja soveltaa saatua tietoa, mutta kaikki kielimallien tekstianalyysisovellukset kuuluvat rajauksen sisälle.

Vaikka suuret kielimallit ovat olleet suuren yleisön tiedossa vasta muutamia vuosia, on niiden potentiaalia yritetty hyödyntää jo usealla eri alalla. Li et al. (2024) keräsivät artikkeliinsa esimerkkejä generatiivisen tekoälyn soveltamisesta teollisessa tuotannossa. Heidän mukaansa mahdollisuudet olivat lähes rajattomat, esimerkiksi laadunvarmistuksessa, kulujen optimoinnissa, toimittajariskiä arvioidessa, 3D-mallinnuksessa sekä useassa muussa käyttökohteessa. He tunnistivat myös useita merkittäviä haasteita kielimallien käyttöönotossa valmistavassa teollisuudessa. Valmistusteollisuus käsittelee erittäin erikoistunutta ja monimutkaista dataa, jolle on ominaista erityiset termistöt, sääntely ja markkinaolosuhteet. Nämä tekijät edellyttävät malleilta kehittynyttä kykyä ymmärtää monimutkaisia kokonaisuuksia. Koska valmistusteollisuudessa toimitaan tarkkojen mittojen ja pienten marginaalien parissa, kielimalleille asetetut odotukset ovat erityisen korkeat. Suuret kielimallit omaavat merkittäviä loogisen päättelyn ja ongelmanratkaisun kykyjä, mutta niiden tehokas ja tarkoituksenmukainen soveltaminen eri valmistusalan tehtäviin on merkittävä haaste, joka vaatii huolellista tarkastelua. (Li et al., 2024, 2)

Esimerkiksi Lu et al. (2024) tutkivat yleisimpien suurien kielimallien kyvykkyyksiä todella tarkan kontekstin puitteissa, joka oli tutkimuksessa lämmitys-, ilmanvaihto-, ja ilmastointiala. Tutkimuksessa kielimallit suorittivat ASHRAE Certified HVAC Designer -kokeen, joka mittaa ammatillista osaamista. Open AI:n GPT-4 menestyi parhaiten ja läpäisi kokeen jokaisella suorituskerralla pistein 74–78, mikä on parempi kuin noin puolet ihmiskokeen suorittaneista. Muiden tekoäly-yhtiöiden kielimallit eivät saavuttaneet hyväksyttyä pistemäärää. Kielimallit suoriutuivat parhaiten tiedon muistamisesta ja analysoinnista, mutta niiden soveltamiskyky oli ihmistä heikompi. Huomioitava seikka on, että kielimallien välillä on suuriakin eroja, jotka tulee ottaa huomioon omaa tarvetta arvioidessaan.

Li et al. (2024) perehtyvät kielimalleihin artikkelissaan myös data-analyysin näkökulmasta. Suurien kielimallien potentiaali esimerkiksi käyttäjäpalautteen ja muun tekstimuotoisen datan analysoinnissa on tunnistettu. Zhou et al. (2024) toteuttivat puolestaan ilmailuteollisuuden valmistusprosessissa ilmenevistä laadullisista ongelmista juurisyyanalyysin, joka toteutettiin LLM-integraation avulla. Valmistusprosessin laatuvirheistä oli kerättynä valtavasti dataa, mutta niiden kausaalinen yhteys oli vielä epäselvää. Tutkimusta varten hienosäädettiin oma kielimalli nimeltään CausalKGPT, joka käyttää syötteenään luonnollisella kielellä tehtyjä kuvauksia laatuvirheistä ja hyödyntää laatuun liittyvää kontekstisidonnaista dataa apunaan syy-seuraussuhteiden selvittämiseksi.

Tutkimuksen lopputuloksena selvisi, että hienosäädetty malli oli asiantuntevampi ja luotettavampi vastauksissaan kuin ainoastaan esikoulutettu kielimalli. Tutkimuksessa huomattiin myös haasteita, jotka liittyivät pääosin käsiteltävän tiedon laatuun. Käytettävän datan esikäsittely eli tiedon yhtenäistäminen ja epäolennaisten tietojen poistaminen asiantuntijoiden avulla oli yksi tutkimuksen keskeisimpiä osia. Tulokset viittasivat kuitenkin siihen, että ehdotettu menetelmä voi tarjota luotettavan työkalun työntekijöille ilmailutuotteiden laatuvirheiden analysoinnissa. (Zhou et al., 2024, 34–37)

Teoreettisen taustan perusteella isojen datamassojen valjastaminen analyyttiseen käyttöön ei ole ollut kaikissa tilanteissa ollut mahdollista. Yksi tällainen tilanne on vapaasti kirjoitetut selosteet, joihin kuuluvat esimerkiksi asiakaspalautteet sekä valmistusprosessin virheraportit. Generatiivisen tekoälyn sovellukset, erityisesti suurten kielimallien muodossa ovat tarjonneet edellä mainittuihin tilanteisiin ratkaisun, joka ensimmäisten tutkimusten

perusteella vaikuttaisi havaituista haasteista huolimatta vähentävän manuaalista taakkaa ja helpottavan data-analyysia. (Zhou et al., 2024; Lu et al., 2024; Li et al., 2024)

2.8 Teoreettisen taustan yhteenveto

Taulukko 2 esittelee teoreettisen taustan keskeiset sisällöt, jotka liittyvät tilausohjautuvaan tuotantoon, eskalointijärjestelmän rooliin tuotannon tehostamisessa sekä suurten kielimallien kehitykseen ja hyödyntämiseen tekstianalyysin tukena. Näiden kolmen elementin yhdistäminen tässä työssä tarjoaa uusia näkökulmia kriittisten asiakastilausten hallintaan.

Tilausohjautuvassa ympäristössä toimivat yritykset kohtaavat usein monimutkaisia ja räätälöityjä asiakastilauksia, jotka vaativat tarkkaa suunnittelua ja joustavaa tuotantoa. Tämä luo haasteita toimitusketjun hallinnalle ja tuotannon tehokkuudelle. Eskalointijärjestelmä puolestaan tarjoaa mekanismin, jolla voidaan nopeasti reagoida odottamattomiin ongelmiin ja varmistaa, että kriittiset tilaukset etenevät aikataulussa.

Suurien kielimallien hyödyntäminen tuo uuden ulottuvuuden eskalointijärjestelmän ja toimitusketjun ongelmien analysointiin. Kielimallien on osoitettu kykenevän analysoimaan suuria määriä vapaamuotoista tekstidataa, kuten eskalointikeskusteluja, ja tunnistamaan toistuvia kaavoja ja juurisyitä. Tämä mahdollistaa aiempaa kattavamman ja nopeamman analyysin, mikä tukee päätöksentekoa ja auttaa ennakoimaan potentiaalisia ongelmia.

Tunnistamalla tilausohjautuvan tuotannon sekä toimitusketjun merkittävimmät haasteet, ja yhdistämällä ne eskalointijärjestelmän tehokkaaseen toteutukseen kielimallien analyysimahdollisuuksia hyödyntämällä, voidaan saavuttaa merkittäviä parannuksia kriittisten asiakastilausten hallinnassa. Tämä integroitu lähestymistapa mahdollistaa resurssien tehokkaamman kohdistamisen mahdollisten ongelmakohtien ratkaisemiseksi.

Taulukko 2. Teoriaosion keskeiset sisällöt

Kappale	Tärkeimmät yksityiskohdat	Merkittävimmät lähteet
2.1 Asiakastilausohjautuvan valmistuksen erityispiirteet	**ETO-yritysten ominaisuudet:** korkea laatu, kustomointi, monimutkaisuus, projektiluontoisuus. **Riskit:** kapasiteettihaasteet, toimittajien epävarmuus ja myöhästymät, epävarmuus asiakasspesifikaatioissa sekä asiakkaan muutokset.	Fortes et al., 2023 Hicks et al.,2000 Seth & Rastogi 2019
2.2 Eskalointijärjestelmän rooli tuotannon tehostamisessa	**Eskalointijärjestelmän vaatimukset:** reaaliaikainen arviointi, häiriöiden estäminen, systemaattinen tiedon tallennus. **Hyödyt:** poikkeamien reaaliaikainen seuranta, ongelmien ohjaaminen oikealle ratkaisuryhmälle, ratkaisujen tehokkuuden mittaaminen, jatkuva kehitys	Gödri, 2024
2.3 Tekoälyn määritelmä ja kehitys	**Tekoälyn määritelmä:** ”Järjestelmän kyky tulkita ulkoista dataa oikein, oppia kyseisestä datasta ja hyödyntää oppimaansa saavuttaakseen tiettyjä tavoitteita ja tehtäviä joustavien sopeutumisten avulla.” **Alakäsitteet:** koneoppiminen, neuroverkot, syväoppiminen, NLP, LLM.	Amaratunga, 2023
2.4 Luonnollisen kielen käsittelystä suurien kielimallien läpimurtoon	**NLP:n tavoitteet:** kehittää algoritmeja ja tekniikoita ihmiskielen ymmärtämiseen. **Suurien kielimallien kouluttaminen:** esikoulutus, hienosäätö, RAG, kehotetekniikka.	Kamath et al., 2024 Arslan et al., 2024
2.5 Suurien kielimallien hyödyntäminen tekstianalyysin tukena	**Suurten kielimallien mahdollisuudet:** helppokäyttöisyys, edullisuus, nopeus. **Laadukas kehote:** roolin määrittäminen, haluttu lopputulos, tarkkuus, konteksti.	Törnberg, 2023 Viswanath, 2024
2.6 Suurien kielimallien haasteet	**Haasteet:** hallusinointi, väärien tietojen esittäminen, kyberturvallisuus, tietovuotoriski, eettiset haasteet. **Hallusinaatioiden syyt:** ymmärrysvirhe, asiavirhe, täsmällisyysvirhe, päättelyvirhe.	Verspoor, 2024 Martino et al., 2023 Zheng et al., 2023
2.7 Kielimallien soveltaminen teollisessa ympäristössä	**Sovellukset:** vapaamuotoisen tekstin analysointi, laadunvarmistus, kulujen optimointi, toimittajariskiä arviointi, 3D-mallinnus sekä lukemattomat muut sovellukset. **Haasteet:** monimutkainen ja heikkolaatuinen data, kontekstisidonnaiset termistöt ja sääntely	Li et al., 2024 Zhou et al., 2024

3 Empiirinen tutkimus

Tässä luvussa esitellään kohdeyrityksen tilaus-toimitusprosessi sekä kriittisten asiakastilausten eskalointiprosessi. Luvun loppupuolella tarkastellaan empiirisen tutkimuksen toteutusta, joka käynnistyy käsiteltävän aineiston esittelyllä. Juurisyiden tutkimuksessa on hyödynnetty pääasiassa itse kehitettyä juurisyybottia, jonka kehitysprosessi kuvataan lopuksi.

3.1 Valmet Flow Control

Valmet Flow Control on yksi Valmetin liiketoimintayksiköistä, joka toimittaa virtauksensäätöteknologioita ja -palveluita prosessiteollisuuden yrityksille. Valmetin venttiilit, pumput ja automaatioteknologiat tunnetaan laadukkaina tuotteina, jotka erottuvat luotettavuudellaan ja korkeilla turvallisuusstandardeillaan. Valmetin tuotteet auttavat asiakkaita parantamaan prosessiensa suorituskykyä ja ympäristötehokkuutta sekä varmistavat materiaalien turvallisen virtauksen. Yrityksen tuotanto on pääosin asiakastilausohjautuva. Monien venttiilien valmistusprosessi sisältää yksilöllisen suunnitteluvaiheen, ja useissa projekteissa voi olla satoja tai jopa tuhansia venttiileitä. (Valmet, 2025)

Valmet Flow Controlin asiakaskuntaan kuuluu muun muassa sellu-, paperi- ja biotuoteteollisuus, uusiutuva energia, öljyn- ja kaasunjalostus, kaivos- ja metalliteollisuus sekä kemianteollisuus. Valmetin ratkaisut mahdollistavat edellä mainittujen toimialojen yrityksille ratkaisujen tuottamisen, jotka tukevat yhteiskunnan ja infrastruktuurin toimintaa. (Valmet, 2025)

3.2 Teollisuusventtiilin valmistusprosessi

Valmet Flow Control valmistaa monenlaisia teollisuudelle tarkoitettuja venttiileitä vaihteleviin olosuhteisiin sekä moniin erilaisiin käyttökohteisiin. Seuraavaksi käsitellään yksinkertaistettuna teollisuusventtiilien valmistusprosessi Helsingin tehtaalla. Tehtaan

arvoketju on esiteltynä Kuvassa 6. Helsingin tehtaalla valmistettavat venttiilit voidaan jakaa kolmeen erilaiseen tuotantoprosessiin:

1. Standardituotantolinja, jossa valmistetaan yksinkertaisia venttiileitä standardikomponenteista.
2. ATO-tuotantolinja, jossa venttiilit koostuvat hieman monimutkaisemmista konfiguraatioista, mutta eivät vaadi esimerkiksi uniikkia suunnittelutyötä.
3. Erikoistuotantolinja, jossa valmistetaan Valmetin liiketoiminnallisesti tärkeimmät venttiilit, joilla pyritään luomaan kilpailuetua kilpailijoihin nähden. Erikoistuotantolinja sisältää myös tuotantolinjan, jossa valmistetaan kaikista raskaimmat venttiilit.

Erikoistuotantolinjan tuotteet vaativat usein uniikkia suunnittelutyötä, koostuvat erityisen korkean standardin mukaisista materiaaleista sekä edellyttävät erityistä huomiota koko valmistusprosessin ajan, jotta työn eteneminen vaaditussa aikataulussa on mahdollista. Fortesin et al. (2023) mukaan tämä on ETO-ympäristössä toimivalle yritykselle hyvin tyypillinen tapa toimia.

Tyypillinen MRO-tilausprosessi alkaa asiakkaan kyselyllä, johon myynti vastaa konfiguroimalla tuotteet ja laatimalla tarjouksen. Asiakas esittää mahdolliset korjausehdotukset, ja myynti muokkaa tarjousta niiden perusteella. Kun tarjous on viimeistelty asiakasta tyydyttäväksi, asiakas tekee tilauksen. Tilauksen jättämisen jälkeen se etenee rikastukseen, jossa tilauksen attribuutit yhdistetään järjestelmän raakadataan. Rikastuksen jälkeen käynnistetään komponentti- ja materiaaliostot, ja tilaus ajoitetaan toiminnanohjausjärjestelmään eri vaiheineen. Projektimyynnissä prosessi on monimutkaisempi ja vaatii huomattavasti enemmän resursseja. Kaikki tilaukset kuitenkin etenevät tehtaan läpi Kuvan 6 mukaisesti, joten niitä ei tarvitse erotella tämän työn rajauksen mukaisesti.

Kuvasta 6 voidaan huomata, että ennen lopullista kokoonpanoa venttiilin osat vaativat erilaisia toimenpiteitä. Toimittajilta tilataan usein venttiilin pesä sekä siihen liittyvät komponentit. Asennoittimet sekä toimilaitteet valmistetaan yleensä itse. Toimittajilta hankitut materiaalit jatkojalostetaan usein koneistamalla, ja tarkasti suunniteltu logistiikka mahdollistaa edellä mainittujen toimintojen yhteistyön. Kokonaisen venttiilin kokoonpano voidaan jakaa kahteen osaan: venttiilikokoonpanoon sekä yhdistelmäkokoonpanoon, jossa

asennoitin, toimilaite ja muut mahdolliset ohjainlaitteet yhdistetään venttiiliin. Venttiili usein myös maalataan venttiilikokoonpanon jälkeen asiakasvaatimusten mukaan.

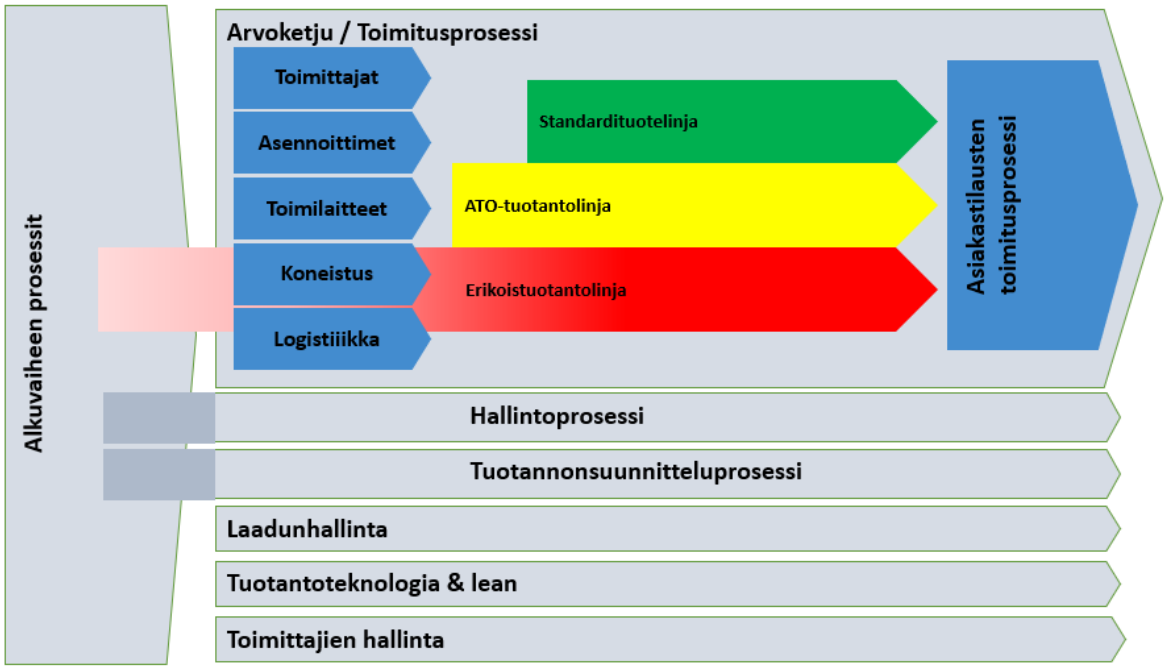

Kuva 6. Helsingin tehtaan arvoketjun ja toimitusprosessin kuvaus

Tilausten korkeiden laatuvaatimusten täyttyminen mahdollistetaan erilaisilla menetelmillä, kuten saapuvien komponenttien laatutarkastuksilla, valmiiden venttiilien koeponnistuksilla sekä muilla tarkastuksilla, joiden pohjana käytetään alan uusimpia standardeja. Kirjallisuudesta Zhoun et al. (2022) sekä Lyneisin ja Fordin (2007) löydökset tukevat laaduntarkastuksia sekä mahdollisimman laajaa testausvaihetta. Mikäli tuotannon aikana kohdataan vastoinkäymisiä tai asiakas haluaa muuttaa vaatimuksiaan, keskeneräiset työt korjataan uudelleentyöstössä, jonka jälkeen ne viimeistellään alkuperäisen tuotantoprosessin mukaisesti.

3.3 Kohdeyrityksen kriittisten asiakastilausten eskalointiprosessi

Valmetin ydinliiketoimintaan kuuluu asiakkaiden käyttöön räätälöidyt uniikit venttiilit, joka asettaa yrityksen tuotannolle sekä toimitusketjulle kovia toimitusaika- ja laatuvaatimuksia. Erilaiset laatuongelmat ja viivästykset ovat yleisiä, vaikka tilaus- ja tarjousvaiheessa pyritään ottamaan huomioon kaikki poikkeukselliset vaatimukset ja kriittisimmille tilauksille pidetään usein myös aloituspalaveri tehtaan toimintojen, myynnin sekä

projektinhallinnan välillä. Tilausten myöhästyminen johtaa asiakastyytyväisyyden heikkenemisen lisäksi usein myös myöhästymissakkoihin. Valmet on reagoinut valmistusprosessin aikana ilmeneviin ongelmiin ottamalla käyttöön kriittisten asiakastilausten eskalointiprosessin.

Tieteellisten julkaisujen määrä asiakastilausten eskalointiprosesseista on rajallinen, mutta kirjallisuus antaa viitteitä siitä, että teollisuusyritykset ovat eriyttäneet hankinnan vauhdittamisen ja tehtaan oman häiriöhallinnan (Gödri, 2024; Oberdorf et al., 2021). Valmetin tapauksessa tämä toiminta on yhdistetty yhdeksi järjestelmäksi, jossa hoidetaan ongelmia rikastuksesta paketointivaiheeseen. Tämän prosessin tavoitteena on varmistaa, ettei tuotteiden toimitus viivästy, ja mikäli odottamattomia tilanteita ilmenee, pyritään viiveet minimoimaan. Eskalointiprosessi käynnistyy usein silloin, kun tilauksenhallitsija huomaa tilauksen valmistumisen kannalta uhkaavia yksityiskohtia materiaalinhallintajärjestelmästä (Kuva 7). Tyypillisimmät syyt liittyvät esimerkiksi materiaalien sekä komponenttien saapumiseen, koneistuksen ja kokoonpanon kapasiteettiin tai toimittajan sekä oman toiminnan laatuongelmiin. Tilauksenhallitsija arvioi, tarvitseeko tilaus akuutteja toimenpiteitä. Mikäli tarvitsee, edetään eskalointiprosessiin. Tilauksenhallitsija avaa tämän jälkeen tehtaalle eskalointipyynnön, jolla hän pyytää lisätietoa mahdollisista ongelmista sekä päivitettyä aikataulua esimerkiksi koneistettavan komponentin valmistumisesta. Pyyntö avataan aina sille henkilölle, joka vastaa juuri kyseisestä prosessin vaiheesta. Eskalointipyynnöt on jaettu kategorioihin, jotka selviävät Kuvasta 7. Tässä vaiheessa tilausta pyritään priorisoimaan sekä parantamaan eri toimintojen läpimenoaikaa mahdollisuuksien mukaan, kunnes tilaus on paketissa (Kuva 7).

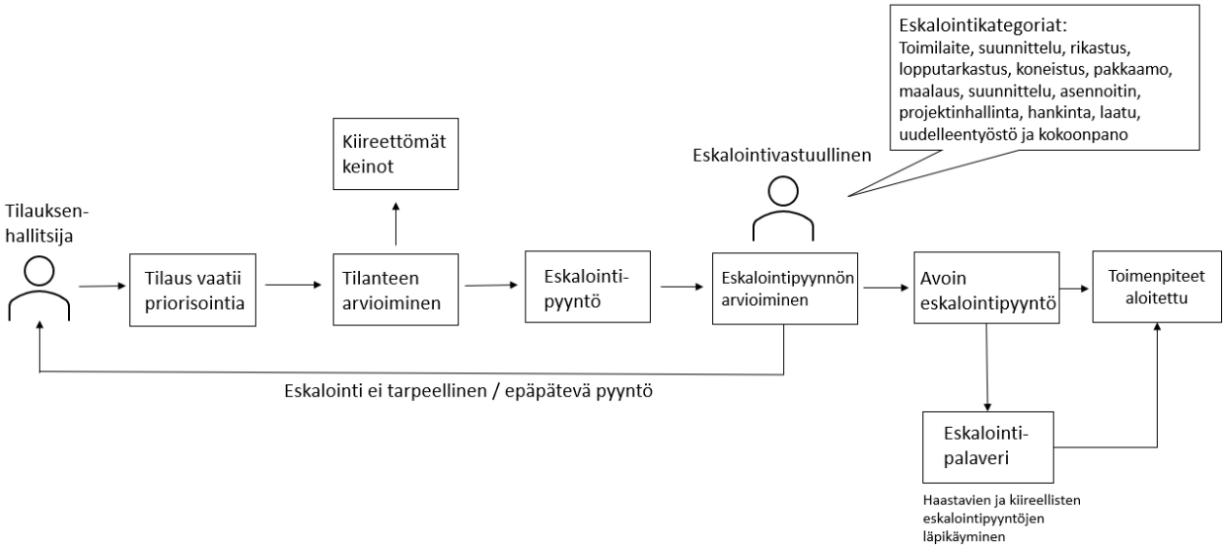

Kuva 7. Kriittisten asiakastilausten eskalointiprosessi

Useimmat eskalointipyynnöt ratkeavat edellisen kappaleen kuvauksen mukaisesti. Kaikista hankalimpiin sekä kriittisimpien tilausten käsittelyyn tämä menettely ei kuitenkaan ole riittävän tehokas, joten kohdeyritys on päättänyt käsitellä näitä hankalia tilauksia kaksi kertaa viikossa järjestettävässä eskalointipalaverissa (Kuva 7). Palaveriin osallistuvat kaikki tehtaan toimintojen päälliköt sekä projektinhallinnan edustajia keskustelemaan mahdollisista ratkaisuista ilmenneisiin ongelmiin. Kyseinen järjestely on todettu tehokkaaksi tavaksi toteuttaa tilausten priorisointia ottamalla mahdollisimman laajasti erilaiset näkökulmat huomioon. Palaverissa käsitellään yleensä esimerkiksi koneistuskapasiteetin tilanne sekä lennätyspyynnöt. Tämän lisäksi keskustellaan muista haastavista tilanteista, jotka pääasiassa myynti on kokenut kriittisiksi eli eskaloinut. Näitä ovat sisäiset ongelmat, kuten kapasiteettiin liittyvät yksityiskohdat, sekä ulkoiset ongelmat, kuten toimittajien laatu tai asiakkaiden tarvepäivämäärän muuttuminen. Viime vuosina eskaloituneiden tilausten määrä on kasvanut, mikä on lisännyt kiinnostusta eskalointipyyntöjen juurisyiden selvittämistä kohtaan. Tavoitteena on toteuttaa proaktiivisia toimenpiteitä, jotta eskalointipalaverissa käsiteltävien aiheiden määrä ei kasvaisi liian suureksi. Eskalointipyynnöt sekä -palaverit on kehitetty odottamattomien haasteiden ratkaisemiseksi, ja tavoitetila on minimoida niiden aiheuttamat ongelmat ilman standardoiduista toimintatavoista poikkeamista.

3.4 Käytettävän aineiston esittely

Tämän diplomityön empiirisen osuuden perustana toimii kohdeyrityksen eskalointipyynnöistä koostuva taulukkomuotoinen data, joka on yhdistetty tilausdataan asiakastilausnumeron perusteella. Tämä yhdistetty aineisto sisältää tiedot pyyntöjen avauspäivämääristä, venttiilityypeistä, myyntiorganisaatioista, asiakkaista, tilauksen arvosta ja määräästä, tavoitellusta toimitusajasta sekä tekstimuotoisen datan keskustelun etenemisestä kunkin asiakastilauksen tilausriveillä. Eskalointidataa on kerätty aikavälillä 2018–2024, mutta myyntidataa oli saatavilla vain vuosilta 2021–2024, joten analyysi toteutettiin eskalointidatankin osalta vuosilta 2021–2024.

Aineisto koostui 7 147 keskustelusta, joissa oli 2–102 kommenttia. Kaikki kommentit oli aikaleimattu. Datan esikäsittelyyn kuului referenssittömien keskusteluiden poistaminen, duplikaattien eliminointi, datan anonymisointi sekä sen muokkaaminen kielimallin analyysille sopivaksi. Analysoitavia eskalointipyyntöjä jäi 6636 kappaletta. Datan anonymisointivaiheessa poistettiin kaikkien henkilöiden, asiakkaiden sekä tavarantoimittajien nimet. Toimintojen vastuuhenkilöiden nimet korvattiin toimintojen nimillä, jotta analyysi olisi suoraviivaisempaa.

Aineisto koostui vapaamuotoisista keskusteluista, joten se ei sisältänyt kaikkia mahdollisia yksityiskohtia, jotka olisivat olleet analyysin kannalta hyödyllisiä. Etenkin syyt, joiden vuoksi keskustelut oli aloitettu, eivät olleet kaikki samalla laajuudella esitettyjä, mikä tulee ottaa huomioon tuloksia analysoitaessa. Kohdeyrityksellä on myös muita keinoja viestiä tuotannon etenemisestä, esimerkiksi sähköpostitse tai Microsoft Teamsin välityksellä. Tämä loi joissain tapauksissa aukkoja keskusteluihin, vaikka yrityksen mukaan viestimistä muilla keinoilla pyritään välttämään.

3.5 Juurisyyanalyysin toteutus ja juurisyybotin kehittäminen

Seuraavaksi esitellään tässä diplomityössä toteutettu juurisyyanalyysi vaiheittain ja perehdytään tarkemmin juurisyybotin kehittämiseen käytännössä. Juurisyyanalyysin prosessi on Otegüin (2014, 187-188) mukaan usein viisiosainen:

1. Määritellään ei-toivottu tapahtuma.
    - Tässä tapauksessa se oli eskalointipyynnön avaaminen.
2. Kerätään tutkimukseen tarvittavat tiedot ja kartoitetaan mahdollisimman laajasti mahdollisia vaikuttavia tekijöitä.
    - Tiedot kerättiin myyntidatasta sekä eskalointikeskusteluista.
3. Hyödynnetään sopivaa menetelmää juurisyiden tutkimiseen.
    - Menetelmäksi valikoitui kielimalleihin perustuva juurisyybotti.
4. Arvioidaan analyysin tulokset ja poistetaan kaikki merkinnät, jotka eivät ole todellisia syitä.
    - Kaikki 48 juurisyyluokkaa jaettiin kullekin toiminnolle ja eliminoitiin tarkastelusta juurisyyt, jotka eivät liittyneet kyseiseen toimintoon.
5. Kehitetään ratkaisuja, joilla voidaan puuttua sekä välittömiin että perimmäisiin syihin.
    - Ratkaisut jaettiin itse eskalointiprosessissa ilmeneviin ongelmiin sekä toimintoihin liittyviin ongelmiin.

Tekstianalyysin ensimmäinen vaihe oli määrittää, mitkä toiminnot ovat eniten osana eskalointiprosessia ja mistä toiminnosta prosessi alkaa useimmiten. Tämä toteutettiin selvittämällä kaikkien keskusteluihin osallistuneiden rooli, jonka jälkeen keskusteluissa esiintyneet nimet korvattiin heidän edustamallaan toiminnolla. Tämän ansiosta pystyttiin yksinkertaisesti määrittämään toiminnot, joille pyynnöt avataan sekä mitkä kaikki toiminnot ovat eniten osallisena eskalointiprosessissa.

Eskalointidatan ytimessä olivat keskustelut, joiden analysointi ei onnistunut perinteisen taulukkolaskennan keinoin. Taulukkolaskennan avulla pystyi erottelemaan esimerkiksi avainsanoja sekä toimintoja, joiden kautta eskalointipyynnöt kulkevat, mutta pääasiallisena tavoitteena oli tutkia, pystyttäisiinkö keskusteludatasta ymmärtämään syy-seuraussuhteita. Ratkaisuksi valittiin suurten kielimallien hyödyntäminen, rajaten muut tekoälymenetelmät työn ulkopuolelle. Pyyntöjä oli kertynyt viimeisen kolmen vuoden aikana 6636 kappaletta, joissa jokaisessa keskustelussa oli 3–100 kommenttia, joten kommenttien manuaalinen läpikäynti ei olisi ollut tehokasta.

Kielimallin valinta alkoi tekoälymahdollisuuksien kartoittamisella. Kohdeyrityksen IT-järjestelmien tarjoaja on Microsoft, joten mahdollisuuksia kartoitettiin Microsoft Copilotin toiminnoista. Kävi kuitenkin ilmi, että Copilot on suunniteltu ensisijaisesti Microsoftin omien ohjelmien käytön tehostamiseen. Valinta kohdistui lopulta OpenAI:n kielimalleihin niiden tehokkuuden ja tunnettuuden vuoksi. Lu et al. (2024) artikkeli täsmentää eri yritysten tarjoamien kielimallien eroja, ja OpenAI osoittautui selkeäksi voittajaksi. Microsoftin ympäristöstä poistuminen loi tietoturvaan liittyviä kysymyksiä, joten keskusteluista poistettiin työntekijöiden, asiakkaiden, alihankkijoiden ja tavarantoimittajien nimet.

Datan anonymisoinnin jälkeen aloitettiin juurisyybotin kehittäminen. Botin toiminnallisuus oli suoraviivainen ja melko yksinkertainen. Botin luomisen osa-alueet olivat seuraavat:

1. Python-skriptin luominen, joka lukee käsiteltävän keskustelun Excelistä ja palauttaa kielimallin vastauksen viereiseen soluun. Tähän hyödynnettiin Pythonin Pandas-kirjastoa.
2. Selkeän kehotteen laatiminen, jossa kielimallille määriteltiin sen rooli, tavoiteltava tuloste sekä relevantti konteksti (Liite 1).
3. RAG-mallin tietokannan luominen, jonka avulla botti pystyi vertaamaan ihmisen tekemää analyysiä omiin johtopäätöksiinsä.
4. Kokeilujen toteuttaminen OpenAI Playgroundissa eri kielimalleilla ja lopullinen toteutus OpenAI API:a hyödyntäen.

Lopullinen kielimalli valittiin GPT-4o-minin ja GPT-4o:n väliltä. Valinta kohdistui lopulta GPT-4o-miniin, sillä sen ominaisuudet olivat riittävät ja se oli noin 100–200 kertaa edullisempi, mikä teki toistuvista iteraatioista kustannustehokkaampia.

Kielimallille (GPT-4o-mini) annettiin ohjeistus, joka kuvasi venttiilien valmistusprosessin, yleisimmät venttiilin osat sekä muita yksityiskohtaisempia tietoja esimerkiksi kirjainyhdistelmistä. Kielimallille annettiin käyttöönsä myös RAG-tietokanta, joka sisälsi 50 manuaalisesti luotua esimerkkivastausta. Näiden vastausten valinnassa pyrittiin varmistamaan, että mahdollisimman suuri osa erilaisista havaituista keskustelun perusmalleista olisi edustettuna.

Tämän jälkeen kielimallia hiottiin niin, että se tuotti mahdollisimman yksiselitteisiä ja oikeita vastauksia. Esimerkkivastauksia sekä kehotetta muokattiin, ja kielimallin vastausten

lämpötila asetettiin lopulta arvoon 0,2. Kielimallin vastausten lämpötila kuvastaa yksinkertaistettuna vastausten ennalta-arvattavuutta: mitä pienempi lämpötila, sitä ennalta-arvattavampia vastaukset ovat, ja mitä suurempi lämpötila, sitä satunnaisempia ne ovat. Paras saavutettu tulos oli, että kielimalli antoi juurisyyn oikein 80 % tarkkuudella ja 95 %:ssa tapauksista vähintään osittain oikein. Tämä tulos saavutettiin 80 % luottamuksella, kun virhemarginaali oli 5 %. Kyseinen tulos saatiin vertaamalla 160 manuaalisesti toteutettua analyysiä kielimallin tuottamiin analyyseihin. Vaikka kyseessä ei ollut tilastotieteellisesti erityisen luotettava koe, työn toteuttamisen kannalta tarkemman ja tilastollisesti luotettavan tuloksen saavuttaminen olisi vaatinut liikaa resursseja. Tämän vuoksi nykyinen taso todettiin riittäväksi yhdessä kohdeyrityksen edustajan kanssa. Kielimallin "kouluttajana" toimi suhteellisen kokematon diplomityöntekijä ja varsinaista testausta toteutettiin rajoitetusti. Tästä syystä juurisyybotin, kuten muidenkin generatiivisten tekoälyjen tuottamien tulosten, kanssa tulee suhtautua varauksella. Toteutuksen voidaan katsoa olevan varsinaisen työkalun ja konseptitodistuksen välimuoto.

Käytännössä kielimalli analysoi keskustelut ja määritti niille yhden tai useamman juurisyyn. Alun perin tavoitteena oli kategorisoida keskustelut vain yhden juurisyyn pohjalta, mutta tuloksia validoitaessa huomattiin, että lähes aina tilauksissa oli useita ongelmia, ja yksiselitteinen kategorisointi olisi johtanut enemmän harhaan kuin moniin eri luokkiin jakaminen. Tämän jälkeen juurisyyt jaettiin seuraavassa vaiheessa ennalta määritettyihin kategorioihin, joita oli yhteensä 48 (Liite 2). Kategorioiden tunnistaminen ja jaottelu perustuivat tekoälyn ehdotuksiin juurisyiden perusteella, omaan kokemukseen, kirjallisuudesta löytyviin esimerkkeihin sekä prosessin kanssa päivittäin työskentelevien asiantuntijoiden mielipiteisiin. Näin saatiin riittävän kattava ja tarpeeksi yksityiskohtainen lista kategorioista. Juurisyiden kategorisointiin juurisyybottia muokattiin hieman, mutta lauseiden jakaminen eri kategorioihin oli kielimallille huomattavasti yksinkertaisempi tehtävä kuin itse juurisyiden tutkiminen. Tämän vuoksi vaadittu konteksti oli huomattavasti pienempi, eikä RAG-tietokantaa tarvittu tukemaan tätä vaihetta

Kun kaikki juurisyyt oli kategorisoitu, aloitettiin niiden manuaalinen analysointi. Eskalointipyynnöt jaettiin kuuteen pääluokkaan, jotka muodostettiin yhdistämällä käytännön näkemyksiä ja Fortes et al. (2023) laatiman ETO-yrityksen ominaispiirteiden analyysiin perustuva kuva (Kuva 2): 1. Keräily / Pakkaamo / Lopputarkastus, 2. Kokoonpano, 3. Tuotannonsuunnittelu, 4. Koneistus, 5. Hankinta ja 6. Uudelleentyöstö

Koska juurisyitä oli lähes aina useita ja eri vaihtoehdot saattoivat vaikuttaa kaikkiin eri luokkiin, pyrittiin tarkastelemaan kutakin aloituskohtaa eliminoimalla selkeät kohdat, jotka eivät vaikuta kyseiseen luokkaan, mutta jotka saattoivat olla merkittäviä tilauksen etenemisen kannalta. Esimerkiksi, kun koneistukselle avattu eskalointipyyntö sai yhdeksi juurisyykategoriaksi "Pakkauksen priorisointi", todettiin, että kyseinen juurisyy ei liity koneistukseen, eikä sitä otettu huomioon analyysissa.

4 Tulokset ja keskustelu

Tässä luvussa käsitellään eskalointiprosessin nykytilaa esimerkiksi tutkimalla eskalointipyyntöjen määrän kehitystä vuosina 2021–2024. Tämän jälkeen esitellään juurisyybotin avulla saavutetut tulokset ja lopuksi arvioidaan juurisyybotin soveltuvuutta juurisyyanalyysin tukena. Tähän lukuun sisältyy myös tulosten peilaaminen aikaisempiin tutkimustuloksiin eli työn keskusteluosio. Näin rakenne tukee sekä objektiivista tulosten esittämistä että kriittistä vertailua aiempien tutkimusten kanssa, tarjoten perusteellisen näkökulman aiheeseen.

4.1 Eskalointiprosessin nykytila

Työn empiirinen osuus aloitettiin strukturoimattoman eskalointidatan analysoimisella ja yhdistämällä se aikaisempaan myyntidataan, jotta saataisiin mahdollisimman laaja kokonaiskuva siitä, kuinka paljon ja minkä tyyppiset tilaukset päätyvät osaksi eskalointiprosessia. Nykymuotoinen eskalointiprosessi otettiin käyttöön vuonna 2018, jolloin eskalointipyyntöjä oli vuosittain noin 600. Vuosina 2022–2024 pyyntöjen määrä vaihteli 1500–1800 vuosittaisen pyynnön välillä. Kaikista tilauksista keskimäärin noin 10 % eskaloidaan. Pyyntöjen määrän kasvu on ainakin osittain selitettävissä sillä, että uuden toimintatavan käyttöönotto ja omaksuminen vievät aikaa. Eskalointiprosessin parissa työskentelevien henkilöiden mukaan myös Covid-19 saattoi vaikuttaa eskalointipyyntöjen määrän kasvuun, mutta pyyntöjen määrä ei ole lähtenyt laskuun pandemian jälkeisinä vuosina.

Eskalointipyynnöt jakautuvat kvartaaleittain kohtuullisen tasaisesti, kuitenkin vaihdellen noin 12 % lukumäärältään suurimman (Q3) sekä pienimmän (Q4) kvartaalin aikana. Kun tutkitaan tilausmäärän sekä eskalointipyyntöjen määrän korrelaatiota, voidaan huomata, että korrelaatiokerroin on 0,031147, joten minkäänlaista lineaarista riippuvuutta ei ole havaittavissa. Kun otetaan huomioon, että tilauspäivästä kestää useimmissa tapauksissa noin 4 kuukautta, että eskalointipyyntö avataan, voidaan korrelaatioita tutkia myös näiden viiveiden kautta. Kun viive on 4 kuukautta, on korrelaatio -0.13684. Näiden edellä mainittujen korrelaatiolaskelmien perusteella voidaan todeta, että tilausmäärän vaihtelu ei

näyttäisi vaikuttavan eskalointipyyntöjen määrään eli kyse on pääosin tilausten laadullisista tekijöistä. Eskalointipyyntöjen aiheuttaman työkuorman vaihtelu on kuitenkin suurta. Jotkut pyynnöt liittyvät vain yhden toiminnon eskaloimiseen ja aktiivinen aika ennen pyynnön sulkemista on muutamia päiviä. Pahimmillaan eskalointipyyntö on aktiivisena useita kuukausia ja kiertää kaikki toimitusketjun toiminnot hankinnasta lopputarkastajiin. Eskalointipyyntöjen lukumäärän kasvu luo siis painetta eri toiminnoille, mutta pyyntöjen lukumäärä ei voi olla ainut indikaattori eskalointiprosessia arvioidessa. Eskalointipyyntöjen laatua käsitellään tämän luvun loppupuolella.

Eskaloiduista tilauksista 87 % toimitettiin myöhässä, mikä on luonnollista, sillä pyyntöjä ei avata tilauksille, joissa tilanne vaikuttaa olevan stabiili ja aikataulutavoite on saavutettavissa. Eskalointiprosessissa tilaukset voidaan jakaa kahteen ryhmään toimitusaikojen perusteella: tilaukset, joiden toimitusaika on alle 100 päivää, ja tilaukset, joiden toimitusaika on 100–300 päivää. Kun tarkastellaan 100–300 päivän toimitusajalla myytäviä tilauksia, 95 % tilauksista oli myöhässä. Alle 100 päivän toimitusajalla myydyt tilaukset poikkesivat muusta massasta, ja olivat vain 56 % myöhässä. Kaikista Helsingin tehtaan tilauksista puolestaan noin 30 % toimitetaan myöhässä. Vaikuttaisi, että joissain tapauksissa eskalointiprosessia käytettäisiin myös proaktiivisesti varmistamaan tilausten pysyminen aikataulussa, vaikka eskalointiprosessin pääasiallisena tavoitteena on löytää reaktiivisia ratkaisuja jo todetun myöhästymän minimoimiseksi.

Valmetin liiketoimintamallin mukaisesti tilaukset jakautuvat projekteihin sekä MRO-liiketoimintaan. Eskalointipyyntöjä voidaan avata kolmen eri tiimin toimesta, jotka ovat projektipuolen tiimi sekä kaksi MRO-puolen tiimiä. Projektiliiketoiminnan liikevaihto on noin 33 % kokonaisuudesta, kun taas MRO vastaa noin 67 %. Kun tätä lukemaa verrataan eskalointipyyntöjen jakautumiseen, voidaan huomata, että projekti- ja MRO-puolen osuudet pysyvä kohtuullisen muuttumattomina: MRO-tilaukset 65 % ja projektit 35 %. Kun tarkastellaan eri tiimien tilausmääriä ja verrataan niitä eskaloituihin tilauksiin, joilla on ainakin yksi eskalointipyyntö, voidaan huomata selkeitä eroja. Projektiliiketoiminnassa n. 8 % tilauksista on eskalointistatus, päivittäispuolella perustilauksista vastaavan tiimin osuus oli n. 2 %. Kaikista vaikeimpia päivittäispuolen tilauksia hoitava tiimi avasi 33 % tilauksista ainakin yhden eskalointipyynnön. Vaikeiden tilausten tiimin rooli on lähtökohtaisesti hoitaa haastavia tilauksia, joten huomattavan suuri osuus ei ole yllättävä. Tilausten

haasteellisuuden tunnistamisen jo alkuvaiheessa voidaan jopa todeta olevan onnistunutta, koska niin suuri osa tilauksista saa lopulta eskalointistatuksen.

Eri tuotantolinjojen tarkastelu paljastaa, että Helsingin tehdas jakaantuu periaatteessa kolmeen tuotantolinjaan: Standardi-, ATO-, ja erikoistuotantolinja. Erikoistuotantolinja kattaa eskaloiduista tilauksista noin 44 %, mikä on luonnollista, sillä vaikeimmat konfiguraatiot kulkevat joko erikois- tai isoille venttiileille tarkoitetun tuotantolinjan läpi. läpi. Seuraavaksi merkittävin tuotantolinja oli nimenomaan isoille venttiileille tarkoitettu tuotantolinja, joka on käytännössä oma tuotantolinjansa, mutta periaatteessa osa erikoistuotantolinjaa. Sen osuus on noin 27 % kokonaisuudesta. ATO ja Standardi vastaavat yksinkertaisimmista venttiiliyhdistelmistä ja niiden osuus oli yhteensä noin 18 %. Loput eskalointipyyntöjen tuotantolinjoista koostuivat yksittäisten komponenttien valmistukseen liittyvistä tuotantolinjoista. Tuotantotuotantolinjojen jakautuminen ei paljastanut mitään ennakko-oletuksista poikkeavaa.

4.2 Juurisyyanalyysin tulokset

Varsinainen juurisyysanalyysi käynnistettiin keskeisten toimintojen tunnistamisella eskalointipyyntöjen osalta. Taulukossa 3 on esiteltynä eskalointipyyntöjen näkökulmasta 8 tuotannon kannalta keskeistä toimintoa. Eskalointipyyntöjen ja tiedossa olevien ongelmien laatua arvioimalla sekä vertaamalla niitä olemassa olevaan kirjallisuuteen, muotoiltiin hypoteesi niistä merkittävistä toiminnoista, jotka voivat olla eskalointipyyntöjen juurisyiden kannalta keskeisiä. Kirjallisuudesta Wagner et al. (2018) nostivat hankinnan, Zhou et al. (2018) uudelleentyöstön ja Tanrisever et al. (2012) tehtaan toimintojen eli tässä tapauksessa etenkin koneistuksen ja kokoonpanon erittäin merkittäväksi tekijäksi asiakastilausten hallinnassa ja myöhästymän minimoimisessa. Tätä hypoteesia tukevat myös Taulukko 3:ssa esitetyt osuudet. Lopulliset merkittäviksi toiminnoiksi valitut toiminnot olivat hankinta (54 %), koneistus (45 %) ja uudelleentyöstö (25 %) sekä lisäksi tuotannonsuunnittelu (44 %), sillä sen vaikutus on nähtävillä kaikissa tehtaan toiminnoissa. Venttiilikokoonpanon ongelmat puolestaan ilmenevät joko uudelleentyöstössä tai liittyvät tehtaan kapasiteettiin, jonka käyttöaste ei selviä priorisointikeskusteluista yksiselitteisesti. Logistiikka, lopputarkastus sekä pakkaamo puolestaan ovat tuotantoprosessin kannalta vain välivaiheita, joiden vaikutus kokonaisuuden kannalta jää todennäköisesti pieneksi eskalointipyyntöjen

juurisyitä kartoittaessa. Kaikki Taulukon 3 kategoriat kuitenkin analysoitiin juurisyybotin avulla.

Taulukko 3. Eskalointipyynnön kohteena olevat toiminnot.

Eskalointipyynnön kohde	Osuus
Venttiilikokoonpano	57 %
Hankinta	**54 %**
Koneistus	**45 %**
Tuotannonsuunnittelu	**44 %**
Logistiikka	31 %
Uudelleentyöstö	**25 %**
Lopputarkastus	20 %
Pakkaamo	17 %

Ennakko-oletuksena oli myös, että se toiminto, jolle eskalointipyyntö avattiin ensimmäisenä, olisi todennäköisesti ainakin osa juurisyytä. Taulukon 4 perusteella selvästi eniten eskalointipyyntöjä avattiin hankinnalle (37 %) ja toiseksi eniten koneistukselle (17 %). Muiden toimintojen osuudet olivat huomattavasti pienempiä. On myös huomionarvoista, että uudelleentyöstö ei ole osana normaalia prosessia, ja tuote ohjataan sinne vasta kun, joku prosessissa tai tuotteessa on epäonnistunut. Tämän takia uudelleentyöstön osuus oli vain 7 %, vaikka todennäköisesti sen rooli juurisyyanalyysissa on merkittävä.

Taulukko 4. Toiminnot, joille eskalointipyyntö avataan ensimmäisenä.

Eskalointipyynnön kohde	Osuus
Hankinta	**37 %**
Koneistus	**17 %**
Tuotannonsuunnittelu	8 %
Venttiilikokoonpano	7 %
Uudelleentyöstö	7 %
Laatu (Vastaanottotarkastus & NDT-testaus)	5 %
Muut (6 toimintoa)	19 %

Taulukoiden 3 ja 4 perusteella tuotantoprosessin ongelmien alkuperät ja eskalointiprosessin juurisyyt liittyvät todennäköisimmin **hankintaan**, **koneistukseen** sekä **uudelleentyöstöön**.

Seuraavaksi esitellään juurisyybotin avulla tehdyn juurisyytutkimuksen tulokset. Juurisyyt esitellään toiminnoittain alkaen tuotantoprosessin loppupäästä eli pakkaamosta päättyen

tuotantoketjun alkupäähän eli hankintaan. Toiminnot ovat 1. Logistiikka / Pakkaamo / Lopputarkastus, 2. Kokoonpano, 3. Tuotannonsuunnittelu, 4. Koneistus, 5. Hankinta ja 6. Uudelleentyöstö.

Analyysin perustana toimii juurisyybotilla tehty juurisyyanalyysi, mutta tukena on kokonaisuuden hahmottamiseksi joissain kohdissa hyödynnetty myyntidataa sekä varmistettu epäselviä syy-seuraussuhteiden mahdollisuuksia eri toimintojen parissa työskenteleviltä ihmisiltä.

Logistiikka, pakkaamo ja lopputarkastus

Ensimmäinen käsiteltävä toiminto on 1. Logistiikka / Pakkaamo / Lopputarkastus. Nämä kategoriat esiintyvät yhteensä noin 35 % eskalointipyynnöistä, mutta näille toiminnoille avataan pyyntö ensimmäisenä vain 5 % pyynnöistä. Juurisyyanalyysin tuloksena oli, että 94 % pyynnöistä, jotka avataan ensimmäisenä näille toiminnoille, johtuu siitä, että halutaan vain vauhdittaa tilauksen etenemistä, joka on myöhässä kokoonpanosta riippumattomasta syystä. Pakkaamon ja lopputarkastuksen tulokset vastasivat ennakko-odotuksia. Logistiikan ainut merkille pantava juurisyy kiirehtimisen lisäksi oli se, että noin 3 % ajasta kerättävä komponentti oli hukassa, mikä johtui joko väärin merkatusta hyllypaikasta tai saldovirheestä. Lopputulema tämän kategorian analyysistä oli se, että eskalointipyyntöjen merkittävimmät juurisyyt löytyvät todennäköisesti prosessin aikaisemmasta vaiheesta.

Kokoonpano

Seuraavana käsittelyssä on toiminto 2. Kokoonpano. Kokoonpano esiintyi 57 % eskalointipyyntöjä, mikä oli eniten kaikista kategorioista. Tälle oli kuitenkin yksinkertainen selitys: Mikäli eskalointipyyntö avataan ennen kokoonpanovaihetta, pyyntö käy hyvin suurella todennäköisyydellä myös kokoonpanon kautta, sillä kokoonpano on jokaisen tilauksen valmistusprosessissa välttämätön. Kokoonpanolle avattiin eskalointipyyntö ensimmäisenä 7 % pyynnöistä. Juurisyyanalyysin tuloksena oli, että 94 % pyynnöistä kysyttiin kokoonpanon edistymistä, koska tilaus oli jo myöhässä tai sitten haluttiin varmistaa venttiilin valmistuminen jo ennalta sovittuun lopputarkastukseen. Mikäli kokoonpanolle sattuu erehdys tai venttiilissä huomataan esimerkiksi rakenteellisia puutteita, ohjataan se uudelleentyöstöön. Näin tapahtui osassa tapauksia, mutta juurisyybotti ei osannut eritellä, missä vaiheessa tuotantoprosessia uudelleentyöstöön siirtäminen tapahtui. Tämä johtui osin siitä syystä, että keskustelu ei ollut yksiselitteistä tai selkeää. Kun tarkastellaan eri

tuotantolinjoja, vaihteli niissä uudelleentyöstöön ohjaamisen määrä 14–36 % välillä. Erikoistuotantolinjassa uudelleentyöstöön ohjaaminen oli yleisintä eli sitä tapahtuu noin 36 % pyynnöistä, jotka avattiin ensimmäisenä kyseiselle kategorialle. Ei siis ole poikkeuksellista, että venttiili siirtyy kokoonpanosta uudelleentyöstöön, mutta tätä aihetta käsitellään enemmän uudelleentyöstön käsittelykappaleessa. Kun verrataan sitä, kuinka monessa pyynnössä kokoonpano esiintyy (57 %) ja kuinka monessa kokoonpano on ensimmäinen vaihe (7 %) vaikuttaisi, että kokoonpanon ongelmat eivät itsessään ole juurisyy, mutta kokoonpanon aikana saatetaan huomata erilaisia puutteita, jotka myöhemmin korjataan esimerkiksi uudelleentyöstössä.

Tuotannonsuunnittelu

Seuraavana käsittelyssä on toiminto 3. Tuotannonsuunnittelu. Tähän kategoriaan kuuluu sekä tuotantolinjatason suunnittelu että yksittäisten komponenttien, kuten toimilaitteen sekä asennoittimien tuotannonsuunnittelu. Tuotannonsuunnittelu esiintyi 44 % eskalointipyyntöjä ja avattiin ensimmäisenä 8 % pyynnöistä. Tuotannonsuunnittelun suuri esiintyvyys (44 %) selittyy sillä, että mikäli jotain tuotannon osa-aluetta halutaan priorisoida, tulee asiasta sopia tuotannonsuunnittelun kanssa. Hypoteesina oli, että tuotannonsuunnittelun tarkastelu itsessään tarjoaisi kokonaisvaltaisen näkymän tehtaan eri toimintoihin. Osittaiseksi ongelmaksi kuitenkin koitui se, että projektinhallinnan ja tuotannonsuunnittelun välillä on muitakin kanavia, jossa hoidetaan ensisijaisesti kiireettömämpiä tapauksia. Aineistoa tutkiessa huomattiin, että keskustelut olivat osassa pyynnöistä jatkumoa näistä muiden kanavien keskusteluista, joten kokonaiskuvan hahmottaminen oli haastavaa. Toinen ongelma liittyi siihen, että usein keskustelunavauksista ei käynyt ilmi, miksi ja kuinka paljon tuotannon päivämäärät olivat muuttuneet, jos näin oli käynyt. Näiden seikkojen vuoksi juurisyybotti ei kyennyt analysoimaan tuotannonsuunnittelun mahdollisia ongelmia riittävän luotettavasti, joten yksiselitteisiä johtopäätöksiä ei voitu tehdä.

Osittaisena ratkaisuna havaittuun ongelmaan oli analysoida manuaalisesti 380 kappaletta tuotannonsuunnittelulle ensimmäisenä avattua pyyntöä. Tuotannonsuunnittelun eskalointipyynnöt jakautuivat taulukon 5 mukaisesti.

Taulukko 5. Tuotannonsuunnitteluun ohjattujen eskalointipyyntöjen jakautuminen.

Kysymykset	**Vastaukset**
Voidaanko asia X vapauttaa tuotantoon? **(61 %)**	- Kyllä (**80 %),** - kapasiteettirajoite **(4 %),** - pyyntö viedä osa toiselta tilaukselta **(2 %)**, - osapuute **(7 %)**, - järjestelmävirheen korjaaminen **(1 %)**, - revisio kesken (**4 %),** - Osa on jo järjestelmän mukaan tuotannossa **(2 %).**
Onko mahdollista ajoittaa asia X paremmin? **(32 %)**	- Kyllä **(75 %).** Loput vaikea määritellä, sillä vaikuttaisi, että keskustelua olisi käyty jo aiemmin. Yleisin kieltävä vastaus: Lista tilauksista, joihin uudelleenajoitus vaikuttaa.
Ei määritettävissä **(7 %)**	

Tulokset osoittivat, että tuotannonsuunnittelulle ohjattujen eskalointipyyntöjen tarkoituksena vaikuttaisi olevan pääosin pyrkimys kiriä järjestelmään kirjattuja tuotannon aloituspäivämääriä. Vastauksissa huomionarvioista on, että osapuute (7 %), osa on jo tuotannossa (2 %) ja revisio kesken (4 %) ovat kaikki selvitettävissä toiminnanohjausjärjestelmästä. Tämän selvitystyön voi tehdä ilman eskalointipyynnön avaamista.

Koneistus

Seuraavana käsittelyssä on toiminto 4. Koneistus. Koneistuksen rooli tuotannon suorituskyvyn kannalta on merkittävä, sillä venttiilin kriittiset komponentit, kuten akselit, sulkuelimet sekä pesät vaativat hyvin usein koneistusta. Koneistus esiintyi osana 45 % eskalointipyyntöjä ja avattiin ensimmäisenä 17 % pyynnöistä, mikä oli toiseksi eniten. Koneistus on jaettu kolmeen osaan: 1. Tiiviste-, 2. sulkuelinkoneistus, sekä 3. suurille venttiilin osille tarkoitettu koneistus. Koneistuksen eskalointipyyntöjen juurisyyt jaettiin viiteen pääluokkaan: Raakamateriaalin saatavuus, koneistuksen kapasiteetti, koneiden huollot ja korjaukset, sekä epäonnistunut koneistus tai pinnoitus ja raakamateriaalin laatu. Kuvassa 8 on havainnollistettuna eskalointiprosessien syitä koneistuksen näkökulmasta. Kaikista merkittävin pääluokka oli raakamateriaalin saatavuus, joka oli vähintään osasyynä

30–45 % eskalointipyynnöistä. Toiseksi merkittävin oli koneistuksen kapasiteetti, joka ilmeni keskustelussa esimerkiksi tulevaisuuteen siirtyvinä valmistumisennusteina. Kapasiteetti oli vähintään osasyynä 25–35 % eskalointipyynnöistä. 7–10 % eskalointipyynnöistä kyseessä oli laatuongelma. Koneiden huollot ja korjaukset kattoivat juurisyybotin analyysin mukaan noin 3–8 % juurisyistä, mutta niiden epäsuora vaikutus on todennäköisesti nähtävissä myös koneistuksen kapasiteetti -kategoriassa. Kaikissa tapauksissa juurisyybotti ei ole osannut kertoa täsmällistä juurisyytä, joten se on jäänyt tunnistamatta. Osuuksien vaihteluväli johtuu eroista koneistusluokkien välillä, joita ei ole yksinkertaistuksen vuoksi eroteltu Kuvaan 8.

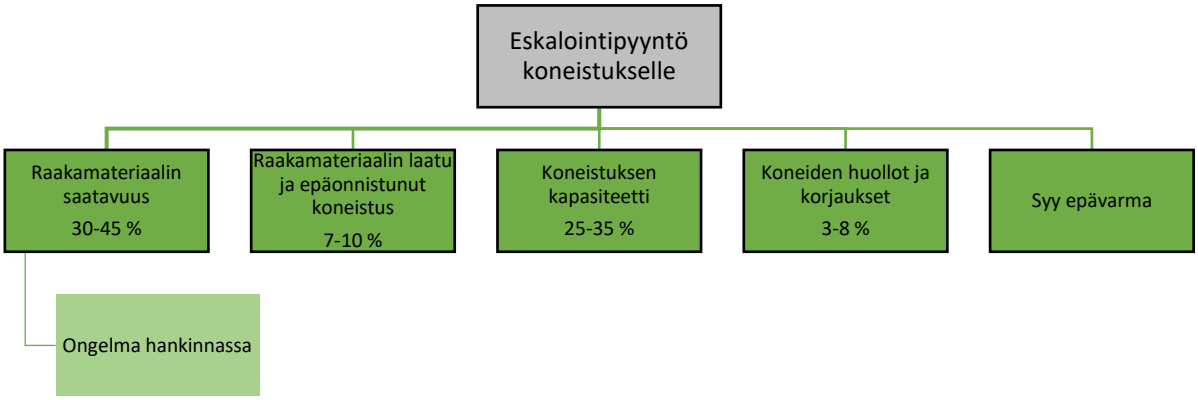

Kuva 8. Koneistukselle osoitettujen eskalointipyyntöjen syykartoitus

Juurisyybotin analyysin tueksi tilannetta analysoitiin myös perinteisen taulukkolaskennan avulla: Koneistus oli osana 2826 eskalointipyyntöä ja näistä 650 eskalointipyyntöä oli alkanut hankinnasta. Hankinta oli yhdessä koneistuksen kanssa ollut ylipäätään osallisena 1426 pyynnössä. Eli yksinkertaistettuna vähintään 23 % ja enintään 50 % koneistuksen ongelmista pystyttiin selittämään hankinnan vaikeuksilla. Tulokset ovat samankaltaiset kuin juurisyybotilla (30–45 %) ja täten ohjaavat keskittymisen kohti hankintaa.

Hankinta

Seuraavana käsittelyssä on toiminto 5. Hankinta koostuu kolmesta hankintaluokasta, jotka ovat materiaali-, komponentti-, sekä valu- ja taoshankinta. Hankinta esiintyi 54 % kaikkia eskalointipyyntöjä ja sille avattiin pyyntö ensimmäisenä 37 % tapauksista. Juurisyybotin tekemän analyysin perusteella hankintaan liittyvät ongelmat selittävät noin 35–50 % kaikista eskalointipyynnöistä tehden siitä merkittävimmän yksittäisen eskalointikategorian. Hankinnan ongelmat jaettiin ennakolta kahteen luokkaan: Tarvittava osa ei ole saapunut ajoissa tai se on heikkolaatuinen. Syytä, miksi näin ei ole käynyt lähdettiin tutkimaan jakamalla eskalointipyynnöt Kuvan 9 mukaisesti.

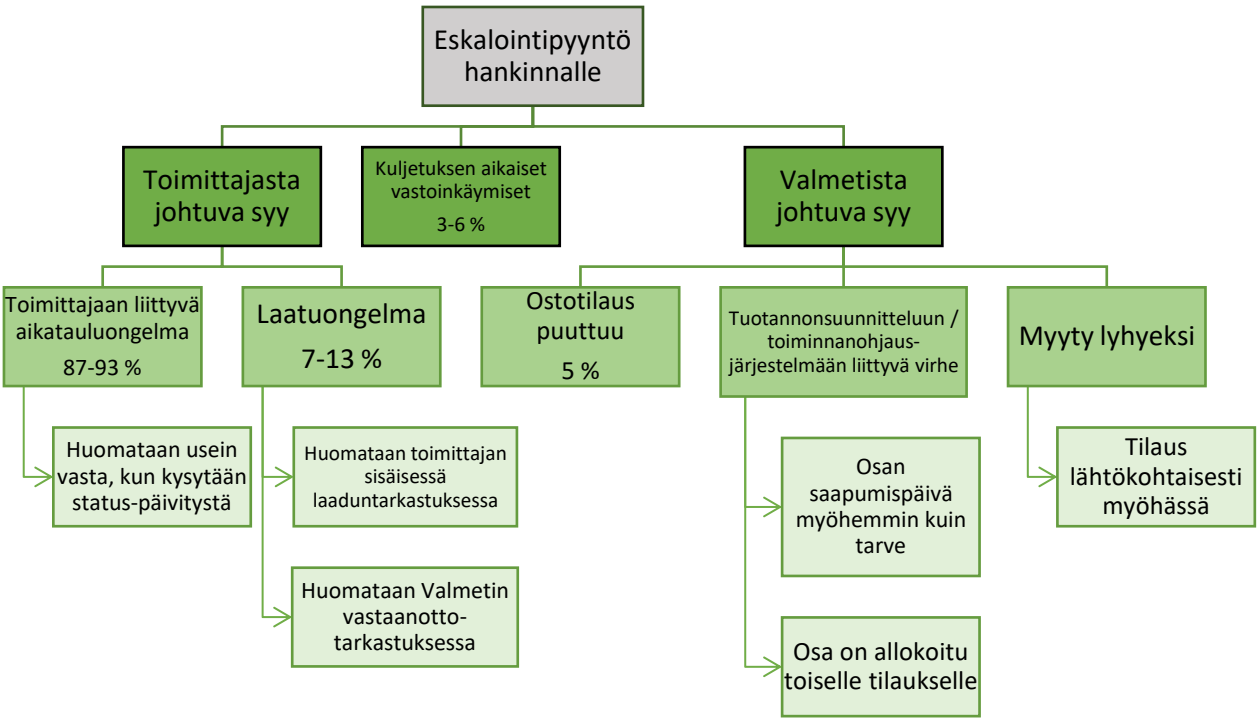

Kuva 9. Hankinnalle osoitettujen eskalointipyyntöjen syykartoitus

Kuvan 9 mukaisia hankinnan ongelmia, pyrittiin lähteä analysoimaan juurisyybotin avulla vielä tarkemmin. Osittaiseksi ongelmaksi analysoinnissa osoittautui keskustelun vapaamuotoisuus, josta harvemmin kävi ilmi se, että onko kyseessä tilauksen ajoitukseen vai toimittajan viiveeseen liittyvä pyyntö. Tämän takia varmoja johtopäätöksiä ei voinut vetää siitä, onko ongelman ydin tavarantoimittajassa, kohdeyrityksessä itsessään vai asiakkaan vaatimuksissa. Aikatauluongelmat olivat kuitenkin osana vähintään 75 % hankinnalle osoitetuista eskalointipyynnöistä. Todellisuudessa luku voi olla vielä suurempi, mutta voi olla, että kaikissa keskusteluissa ei ole keskusteltu aikataulusta suorin ilmauksin, mikä pienentää aikatauluun liittyvien ongelmien osuutta. Aikatauluongelmien suuri osuus on luonnollista, koska pyyntöjen perimmäinen tarkoitus on varmistaa tai parantaa nykyistä saapumisaikataulua. Kuljetuksen aikaiset vastoinkäymiset kattoivat juurisyistä 3–6 %.

Kun tarkastellaan Valmetista johtuvia syitä, vain kaksi selkeää kategoriaa nousi esille, eli oston tekemä virhe, joka johtaa siihen, että ostotilaus on jäänyt tekemättä. Tämä kattoi noin 5 % eskalointipyyntöjä. Toinen kategoria oli tuotannonsuunnitteluun liittyvät ongelmat, joita ei voinut kommenttien perusteella jaotella, koska tuotannonsuunnitteluun liittyvät ongelmat eivät olleet osana keskusteluja. Viimeinen Valmetista johtuva syy, joka vaikuttaa koko toimitusketjun suorituskykyyn oli lyhyeksi myyminen. Yksinkertaistettuna se tarkoittaa myynnin toimintaa, jossa ohjeistettuja läpimenoaikoja ei noudateta, vaan pyritään myymään mahdollisimman paljon tarjoamalla asiakkaille houkuttelevampia toimitusaikoja. Tahtotilana oli tutkia näiden lyhyeksi myyntien vaikutusta tuotantoon, mutta myyntidataan perehtyminen sekä keskustelut asian parissa työskentelevien kanssa johtivat siihen, että lyhyeksi myymistä ei voi varmentaa datasta saumattomasti, sillä usein kirjaukset järjestelmään ei vastaa suullista lupausta asiakkaalle. Käytännössä Valmetista johtuvista syistä 5 % johtui ostotilauksen puuttumisesta ja loput 95 % jäi selvittämättä.

Kun tarkastellaan toimittajaan liittyviä ongelmia, laatuun liittyvät ongelmat pystyttiin tunnistamaan selkeästi. Toimittajalaatu oli vähintään osasyy 7–15 % eskalointitapauksista. Osuuksien vaihteluväli johtuu eroista hankintaluokkien välillä, joita ei ole yksinkertaistuksen vuoksi eroteltu Kuvaan 9. Valu- ja taoshankinnassa oli selkeästi eniten laatuun liittyviä ongelmia: Venttiilin pesä oli heikkolaatuinen 12 % eskalointipyynnöistä. Loput 87–93 % juurisyistä riippui toimittajien omien prosessien toimimattomuudesta ja kyvyttömyydestä vastata Valmetin kysyntään.

Hankinnalle osoitettujen eskalointipyyntöjen syiden kartoittamisen jälkeen pyrittiin tutkimaan, vaikuttaako eskalointipyyntöjen avaamisajankohta tilausten kokonaismyöhästymään. Tilannetta pyrittiin hahmottamaan tarkastelemalla yksittäiselle tilaukselle ensimmäisenä avattuja eskalointipyyntöjä. Hankinnalle avattiin eniten eskalointipyyntöjä ja aikaisempien kappaleiden tulokset viittaavat siihen, että suuri osa eskalointipyyntöjen juurisyistä riippuu hankinnan suorituskyvystä, joten hankinnalle ensimmäisenä osoitetut eskalointipyynnöt asetettiin kuvaajaan (Kuva 10), jossa x-akseli kuvaa eskalointipyynnön avaamisajankohtaa suhteessa tavoiteltuun toimituspäivään ja y-akseli kuvaa keskimääräistä kokonaismyöhästymää. Täytetty alue kuvastaa eskalointipyyntöjen määrää. Datasta on poistettu eskalointipyynnöt, joiden juurisyynä olivat laatutekijät, jotta analyysissa voitiin keskittyä aikataululliseen tekijöihin. Tämä rajaus oli tarpeellinen, sillä esimerkiksi vaurioituneen osan korvaamista ei voida olosuhteiden takia ennakoida.

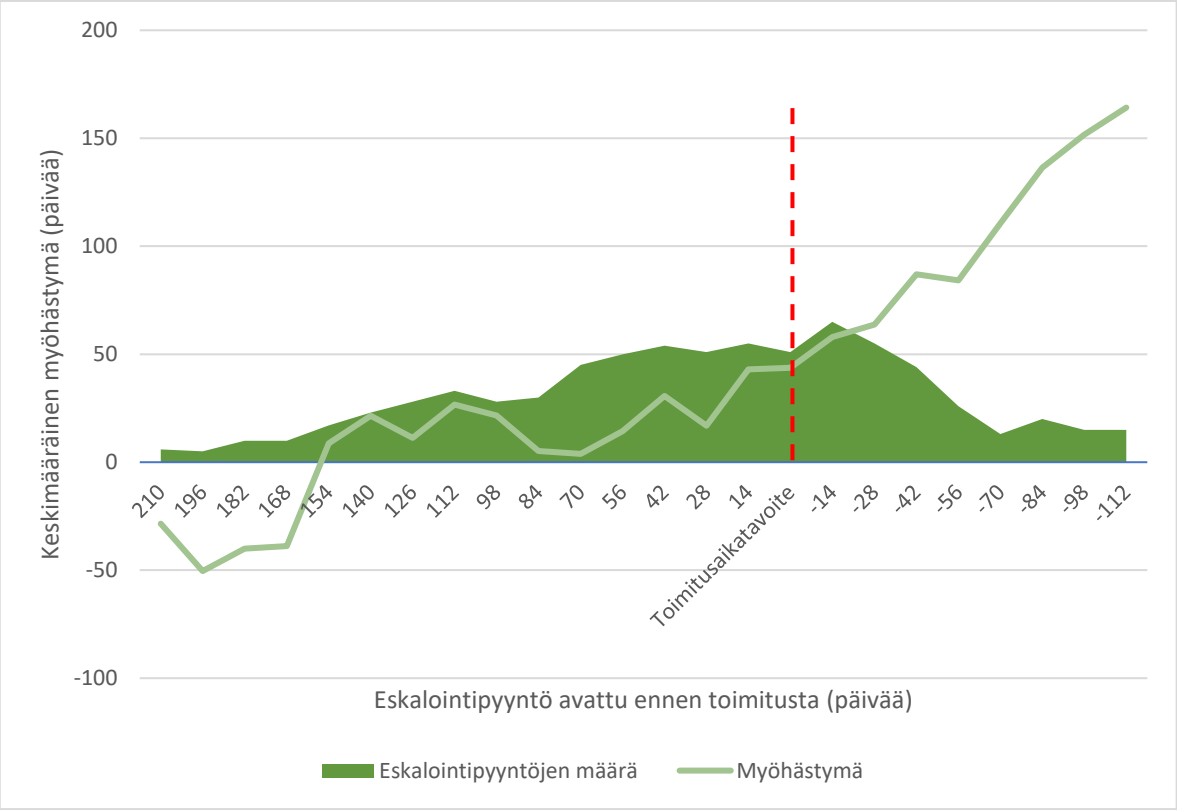

Kuva 10. Eskalointipyynnön avaamisajankohdan vaikutus kokonaismyöhästymään

Kuvaajasta (Kuva 10) voidaan huomata, että mikäli eskalointipyyntö avataan tarpeeksi aikaisin, voidaan potentiaalinen myöhästyminen vielä estää. Keskimääräinen myöhästymä on vähäisintä, kun eskalointipyyntö avataan yli 154 päivää ennen toimituspäivää. Kyseessä

on todennäköisesti ennalta haastava tai muuten erikoistarkkailua vaativa tilaus, joiden aikataulu halutaan varmistaa, sillä on harvinaista, että eskalointipyyntöjä avataan lähes puoli vuotta ennen toimitusta. 84–154 päivää ennen suunniteltua toimitusta avattujen eskalointipyyntöjen tilaukset ovat enemmän myöhässä kuin tilaukset, joille pyyntö on avattu jopa 40 päivää myöhemmin. Tämä voi liittyä tilauksen poikkeukselliseen haastavuuteen.

Kun eskalointipyyntö avataan noin 60–83 päivää ennen tilauksen toimitusta, näyttäisi, että myöhästymä saadaan minimoitua. Alle kaksi kuukautta ennen tavoiteltua toimituspäivää avatut eskalointipyynnöt eivät näytä saavan samanlaista vaikutusta aikaiseksi, vaan myöhästymä jatkaa kasvuaan mitä lähemmäksi toimituspäivää edetään. Huomionarvoista on myös se, että lähes 30 % tilausten ensimmäisistä hankinnalle osoitetuista eskalointipyynnöistä avataan vasta toimitusaikatavoitteen jälkeen ja kaikista eniten eskalointipyyntöjä avataan vasta kaksi viikkoa tavoitellun toimituspäivän jälkeen.

Uudelleentyöstö

Seuraavana käsittelyssä on toiminto 6. Uudelleentyöstö. Uudelleentyöstö oli osana 30 % tilauksia, joille avattiin vähintään yksi eskalointipyyntö. Uudelleentyöstö poikkeaa muista toiminnoista, sillä se ei ole osa normaalia tuotantoprosessia, vaan sen tarkoitus on hoitaa tuotannon aikana ilmeneviä ongelmia. Tämän takia uudelleentyöstön osuutta kokonaismyöhästymään pystyttiin mallintamaan vertaamalla uudelleentyöstöprosessin läpikäyneitä tilauksia niihin, jotka selvisivät ilman uudelleentyöstöprosessia tuotannon läpi. Tilauksille, joille avattiin vähintään yksi eskalointipyyntö ja jotka kävivät tuotantoprosessin aikana uudelleentyöstössä, keskimääräinen myöhästymä oli 63 päivää. Puolestaan tilaukset, joille avattiin vähintään yksi eskalointipyyntö, mutta uudelleentyöstö ei ollut osana valmistusprosessia, myöhästymä oli keskimäärin 53 päivää. Yksinkertaistettuna uudelleentyöstö lisää keskimäärin 10 päivää tai 16 % tilauksen myöhästymää, mutta käytännössä uudelleentyöstöön kuluva aika voi vaihdella muutamasta tunnista useaan kuukauteen. Tämän takia uudelleentyöstöön joutumisen syy vaati syvempää perehtymistä. Edellä mainitut tulokset kuitenkin vahvistavat aiempien tutkimusten havaintoja, joiden mukaan uudelleentyöstön vaikutus aikatauluun kasvaa erityisesti tiukoissa projektiaikatauluissa (Xu, 2020; Zhou et al., 2022).

Uudelleentyöstön syvempi perehtyminen aloitettiin jakamalla uudelleentyöstö yhdeksään eri kategoriaan, jotka kattaisivat suurimman osan uudelleentyöstön kohtaamista ongelmista.

Kategorisoinnin perustana toimi juurisyybotin analyysi mahdollisista uudelleentyöstökategorioista, mutta luokittelun täsmentämiseksi keskusteltiin uudelleentyöstön kanssa päivittäin työskenteleviltä henkilöiltä mielipide siihen ovatko kielimallin antamat kategoriat riittävän laajoja, mutta tarpeeksi tarkkoja. Uudelleentyöstökategoriat ovat esiteltynä Taulukossa 6.

Taulukko 6. Uudelleentyöstökategoriat

	Uudelleentyöstökategoria	Osuus
1	**Tiiviste- ja vuoto-ongelmat**	**21 %**
2	Maalaukseen liittyvät ongelmat	5 %
3	**Koneistus- ja valmistusvirheet**	**13 %**
4	Rakenteelliset ongelmat	8 %
5	Kokoonpanoon liittyvät ongelmat	14 %
6	Merkintä- ja dokumentointivirheet	2 %
7	**Revision seurauksena tehdyt muutokset**	**17 %**
8	Viallinen komponentti	4 %
9	Kategoriaa ei tunnistettu	16 %

Merkittävimmät kategoriat olivat osuuksien perusteella 1. Tiiviste- ja vuoto-ongelmat (21%), 7. Revision seurauksena tehdyt muutokset (17%) sekä 5. Kokoonpanoon liittyvät ongelmat (14%). Tuloksia tarkastaessa kuitenkin huomattiin, että kategoria 5 ei usein liittynyt itse kokoonpanon epäonnistumiseen, vaan siihen, että jokin muu kategoria huomattiin kokoonpanovaiheessa. Tästä syystä kolmanneksi merkittäväksi kategoriaksi nousi 3. Koneistus- ja valmistusvirheet (13 %). Kategoriaa ei tunnistettu usein siitä syystä, että kokoonpano ja uudelleentyöstö olivat keskustelleet asiasta muiden kanavien välityksellä ja eskalointikeskustelussa ainoa maininta uudelleentyöstöistä oli ”uudelleentyöstö valmis”. Ongelman kuvaus oli usein myös todella yksinkertaistettu, mikä hankaloitti kategorisointia ja syvempää perehtymistä. Tarkemman uudelleentyöstöanalyysin saavuttamiseksi tulisi analysoida virheraporttitietokantaa keskusteluiden tukena.

Seuraavaksi otettiin käsittelyyn edellä mainitut uudelleentyöstö-kategoriat venttiilityypeittäin, jotta ongelmien lähteitä voitaisiin kohdistaa tarkemmin. Yksittäisiä venttiilityyppejä oli tarkastelussa 50 ja kun nämä jaettiin vielä koon perusteella omiin luokkiin, yksittäisiä venttiilejä oli 441.

Taulukko 7. Uudelleentyöstöongelmat venttiilimalleittain.

Ongelman kuvaus:	TOP-venttiilimallit (vähintään 5 tapausta):
Uudelleentyöstö (mikä tahansa)	**1. Venttiili A (74 kpl)** **2. Venttiili B (72 kpl)** 3. Venttiili C (50 kpl)
Tiiviste- ja vuoto-ongelmat	1. Venttiili D (10 kpl) 2. Venttiili E (8 kpl) **3. Venttiili A (7 kpl)** **4. Venttiili B (6 kpl)** 5. Venttiili F (6 kpl) 6. Venttiili G (5 kpl)
Revision seurauksena tehdyt muutokset	1. Venttiili H (7 kpl) 2. Venttiili I (7 kpl) **3. Venttiili A (6 kpl)** 4. Venttiili J (5 kpl)
Koneistus- ja valmistusvirheet	**1. Venttiili B (14 kpl)** 2. Venttiili C (8 kpl) 3. **Venttiili A (5 kpl)**
Rakenteelliset ongelmat	**1. Venttiili A (7 kpl)** 2. Venttiili C (5 kpl)

Taulukkoon 7 on listattuna kaikki uudelleentyöstökategoriat, joissa ainakin yhdellä yksittäisellä venttiilillä on yli 5 tapausta kyseisessä kategoriassa. Taulukon 7 perusteella C-, D- ja E-sarjan venttiilit olivat edustettuina merkittävimmissä uudelleentyöstökategorioissa. Venttiilit A ja B vaikuttivat olevan kaikista alttiimpia uudelleentyöstölle, kun venttiilin sarja sekä koko otetaan huomioon. Taulukon 7 venttiilimallit ovat anonymisoitu kohdeyrityksen pyynnöstä.

4.3 Juurisyybotin analysointiominaisuuksien arviointi

Työn teoreettisessa osuudessa perehdyttiin kielimallien potentiaalisiin käyttökohteisiin ja Zhou et al. (2024), Lu et al. (2024) sekä Li et al. (2024) totesivat artikkeleissaan kielimallien tarjoavan tehokkaan mahdollisuuden manuaalisen tekstianalyysin korvaajaksi. Tämän työn empiirisessä osuudessa toteutettu juurisyybotti todisti nämä kyvykkyydet. Botin

suorituskyky suhteessa manuaalisesti toteutettavaan tekstianalyysiin oli huomattavasti parempi. Manuaalisesti tehtävä analyysi ei ole käytännössä ollut mahdollista, sillä dataa on ollut niin paljon, että siihen perehtyminen ilman toimintaa tehostavaa työkalua, olisi vienyt jopa satoja tunteja. Asiantuntijan tekemässä manuaalisessa analyysissa on kuitenkin omat vahvuutensa, sillä vapaamuotoisen tekstin analysoinnissa erilaiset todella spesifit, jopa tilauskohtaiset kontekstit ovat hankala istuttaa juurisyybotin kehotteeseen, kun analysoinnin kohteena on tuhansia keskusteluita. Asiantuntija pystyy myös kokemuksellaan tunnistamaan yrityksen sisäisiä toimintatapoja ja tekemään oletuksia, jotka eivät ole yksinkertaista kertoa kielimallille. Oletusten tekemisessä piilee tosin myös vaara, sillä analyysista voi tulla huomaamatta puolueellinen tai vinoutunut.

Kielimallin tekemän analyysin heikkoutena on myös sen vakuuttavat vastaukset, vaikka todellisuudessa ne saattaisivat perustua hyvin huteralle pohjalle. Juurisyybotin paras saavutettu tarkkuus oli se, että kielimalli antoi juurisyyn 80 % tarkkuudella täysin oikein sekä 95 % vähintään osittain oikein. Tämä toteutettiin 80 % luottamuksella, kun virhemarginaali oli 5 %. Kyseinen tulos saatiin, kun verrattiin 160 manuaalisesti toteutettua analyysiä kielimallin tekemään analyysiin. Mikäli juurisyybotista haluaisi täysin luotettavan, tulisi sen ympärille rakentaa kattava ja ammattimainen testausjärjestelmä. Esimerkiksi Zhou et al. (2024) hienosäätivät oman juurisyybottinsa lentoteollisuuden ongelmien analysointiin ja tulokset vaikuttivat lupaavilta. Tämän diplomityön puitteissa vastaavan järjestelmän rakentaminen ei olisi ollut mahdollista nykyisten resurssien sekä osaamistason puitteissa. Myöskään keskustelun laatu ei kaikissa tapauksissa ollut riittävä, jotta varmempia johtopäätöksiä olisi voinut tehdä luotettavasti esimerkiksi tuotannonsuunnittelun roolista tai hankinnassa Valmetin ja toimittajan syiden jakautumisesta. Mikäli kielimalleja halutaan hyödyntää laajemmin eskalointidatan analysoinnissa, tulee keskusteluiden sisältää enemmän informaatiota kyseisestä tilauksesta sekä relevanteista tapahtumista. Jos kohdeyritys haluaa kehittää eskalointipyyntöihin automaattisesti tehtävän juurisyyanalyysi-integraation, joka kytkeytyy suoraan käytössä olevaan tietojärjestelmään, on se tämän työn perusteella mahdollista toteuttaa. Merkittävin rajoittava tekijä on kerättävän datan laatu.

5 Johtopäätökset

Tämän diplomityön tavoitteena oli tutkia kriittisten asiakastilausten eskalointiprosessin juurisyitä kohdeyrityksessä, joka toimii valmistavan teollisuuden tilausohjautuvassa ympäristössä. Tavoitteena oli myös arvioida, voidaanko suuria kielimalleja hyödyntää tutkimuksen apuna. Tulokset osoittavat, että eskalointipyyntöjen määrä on viime vuosina vakiintunut aiempaa korkeammalle tasolle, ja niiden hallinta edellyttäisi nykyistä systemaattisempaa lähestymistapaa. Vaikka juurisyybotti pystyi tehokkaasti analysoimaan suuria tekstimassoja ja tunnistamaan toistuvia kaavoja, sen käyttö yksinomaisena analyysityökaluna ei ole suositeltavaa. Tämän luvun loppupuolella käydään lisää keskustelua tutkimustuloksista ja verrataan tuloksia aikaisempaan kirjallisuuteen.

5.1 Vastaukset tutkimuskysymyksiin

Tutkimuksen tavoitteen täyttämiseksi työn alussa on laadittu kolme tutkimuskysymystä, joiden avulla lähestytään käsiteltävää ongelmaa. Perustuen esitettyyn teoriaan sekä tutkimuksessa tehtyihin havaintoihin, vastataan seuraavassa vaiheessa esitettyihin tutkimuskysymyksiin.

Tutkimuskysymys 1. *Mitkä ovat juurisyyt eskalointipyynnön avaamiselle?*

Tulokset osoittivat, että eskalointipyyntöjen taustalla on laaja kirjo ongelmia, joista merkittävimmät liittyvät materiaalien ja komponenttien saatavuuteen, tehtaan kapasiteettiongelmiin sekä uudelleentyöstöprosessien vaikutuksiin. Toimitusketjun häiriöt, kuten toimittajaviiveet ja materiaalien laatuongelmat, aiheuttavat huomattavan osan eskaloinneista ja lisäävät epävarmuutta toimitusaikatauluissa. Tehtaan kapasiteetinhallinnan haasteet puolestaan näkyvät erityisesti resurssien allokointihaasteina. Uudelleentyöstö osoittautui yhdeksi merkittävimmistä myöhästymien aiheuttajista. Uudelleentyöstössä merkittävimmät juurisyykategoriat olivat tiiviste- ja vuoto-ongelmat, revision seurauksena tehdyt muutokset sekä koneistus- ja valmistusvirheet.

Tutkimuskysymys 2. *Miten suuria kielimalleja voidaan hyödyntää eskalointidatan analysoimisessa?*

Suurten kielimallien hyödyntäminen eskalointidatan analysoinnissa tarjosi uudenlaisia näkökulmia eskalointiprosessin kehittämiseen. Valittu kielimalli pystyi tunnistamaan ja luokittelemaan eskalointien syitä, mikä mahdollisti aiempaa kattavamman analyysin kriittisten ongelmien toistuvuudesta ja trendeistä. Kielimallia käytettiin pääosin vapaamuotoisen tekstidatan käsittelyssä, jossa se osoittautui hyödylliseksi työkaluksi, sillä se pystyi jäsentämään ja tunnistamaan tekstiaineistosta säännönmukaisuuksia, joita perinteisillä analyysimenetelmillä olisi ollut vaikea havaita. Tekoälyavusteinen analyysi täydensi perinteisiä tilastollisia menetelmiä ja tarjosi mahdollisuuden automatisoida osia eskalointidatan käsittelystä.

Suurten kielimallien käyttöön liittyi myös haasteita, kuten kontekstuaalisen ymmärryksen rajallisuus, analysoitavien keskusteluiden laatu ja tulosten validoinnin tarve. Juurisyybotin osalta sen tarkkuus juurisyiden tunnistamisessa oli lupaava: se pystyi määrittämään juurisyyn täysin oikein 80 % tapauksista ja vähintään osittain oikein 95 % tapauksista. Tämä osoittaa, että teknologia voi toimia hyödyllisenä tukena päätöksenteossa, mutta sen tueksi tarvitaan kattavampi validointijärjestelmä, jotta varmistetaan analyysin luotettavuus. Lisäksi juurisyybotin tuottama analyysi ei aina ollut riittävän kontekstisidonnainen yksittäisten tilausten tarkasteluun, mikä korostaa asiantuntijoiden roolin merkitystä prosessin kehittämisessä. Jotta suurten kielimallien tarjoamaa analyysia voidaan hyödyntää tehokkaammin, integrointi yrityksen tietojärjestelmiin ja eskalointiprosessin päätöksentekoon vaatii jatkokehitystä, joka koostuu mallin hienosäätämisestä, laajemmasta testaamisesta sekä käsiteltävän keskusteludatan sisältävän informaation parantamisesta. Nykyisellä tasolla toteutettu analyysi on lähempänä konseptitodistusta kuin varsinaista toteutusta, sillä analyysista voi tehdä karkeita johtopäätöksiä, mutta kielimallia tulisi vielä hienosäätää tarkempien sekä luotettavimpien tulosten saavuttamiseksi.

Tutkimuskysymys 3. *Miten eskalointiprosessia voi kehittää juurisyyanalyysin pohjalta?*

Tutkimustulosten perusteella eskalointiprosessin kehittämiseksi suositellaan useita toimenpiteitä. Kirjallisuuden perusteella etenkin toimitusketjun läpinäkyvyyden parantaminen esimerkiksi toimittajayhteistyön ja reaaliaikaisen tiedonjaon avulla voi vähentää eskalointien tarvetta ja ennakoida potentiaalisia toimitusviiveitä. Vaikuttaisi myös, että eskalointipyynnöt hankinnalle saatetaan avata liian myöhään, sillä tulokset osoittivat, että eskalointipyynnön oikea-aikaisuus on tärkeää tilauksen myöhästymän minimoimisessa. Vaikka kyseinen yksinkertaistus jättää huomiotta joitain yksityiskohtia, kuten ongelmien merkittävyyden ja olosuhteet, ongelmien tiedostaminen mahdollisen aikaisessa vaiheessa mahdollistaa usein laadukkaampien toimenpiteiden toteuttamisen. Lisäksi etenkin revisioiden minimointi suoraviivaistaisi prosessin etenemistä, ilman tarvetta turvautua uudelleentyöstöön, joka hidastaa tuotantoa. Tietyt venttiilimallit korostuivat uudelleentyöstössä, jonka seurauksena on suositeltava tarkastella näiden venttiilien ongelmia vielä tarkemmin.

Eskalointiprosessin tulisi olla mahdollisimman yksiselitteinen, jota auttaisi eskalointipyyntöjen avaamiselle tarkoitetut tarkat kriteerit esimerkiksi asiakkuuden, tilauksen arvon tai muun attribuutin perusteella. Tällä hetkellä eskalointipyynnön tarpeellisuuden arviointi on tilauksenhallitsijan subjektiivinen kokemus, joten käytännössä kaikki tilaukset ovat yhtä arvokkaita, kunnes niistä keskustellaan eskalointipalaverissa. Myös Gödrin (2024) artikkelissaan esittelemästä eskalointijärjestelmän toimintamalleja voisi tarkastella Valmetin näkökulmasta. Etenkin automaattinen aikarajoihin sidottu eskalointi voisi vähentää epäselvyyttä esimerkiksi vastuun jakautumisesta.

Toimenpiteet tukevat eskalointiprosessin kehittämistä kohti systemaattisempaa ja ennakoivampaa toimintaa, mikä on kirjallisuuden mukaan suositeltavaa ja tukee myös Valmetin pitkän aikavälin tavoitteita.

5.2 Toimenpidesuositukset

Tämän kappaleen tarkoituksena on täsmentää kolmannen tutkimuskysymyksen vastausta eli *Miten eskalointiprosessia voi kehittää juurisyyanalyysin pohjalta?* Perinteisen

taulukkolaskennan sekä juurisyybotin avulla tehtyjen havaintojen perusteella tulokset voidaan jakaa kahteen luokkaan: Ongelmat itse eskalointiprosessissa sekä toiminnoille tyypilliset ongelmat. Toimenpide-ehdotukset ovat koottuna Taulukkoon 8.

Taulukko 8. Toimenpide-ehdotukset

	Ongelman kuvaus	Toimenpide-ehdotus
1	Eskalointipyyntöjen kasvanut määrä.	Selkeä kriteeristö.
2	Materiaalien ja komponenttien aikataulumuutoksiin ei kyetä reagoimaan tarpeeksi ajoissa.	Automaattinen hälytysjärjestelmä aikataulumuutoksista tilaustenhallitsijoille.
3	Suuressa osassa eskalointikommenteista toimenpiteen valmistumisaikataulua kysellään jatkuvasti.	Toiminnanohjausjärjestelmän aktiivinen päivittäminen valmistumispäivämäärien osalta.
4	Tuotantoon vapauttamista käsitteleviin kysymyksiin joudutaan vastaamaan, vaikka tieto olisi saatavilla toiminnanohjausjärjestelmästä.	Korostettu huolellisuus taustatietojen selvittämisen osalta.
5	Hankintaan liittyvät ongelmat ovat merkittävin yksittäinen tekijä tilausten kokonaismyöhästymässä.	Toimittajayhteistyön syventäminen liikennevalomallin avulla.
6	Uudelleentyöstö lisää 10 päivää tilauksen keskimääräiseen myöhästymään.	Turhien revisioiden karsiminen tilauksen tarjousvaiheen huolellisuutta kasvattamalla. Esille nousseiden venttiilimallien ongelmiin syventyminen.

Ensimmäiseksi käsitellään itse eskalointiprosessissa ilmeneviä ongelmia. Ensimmäinen huomio kiinnittyi eskalointipyyntöjen määrään, joka on kolminkertaistunut vuodesta 2018 lähtien. Vaikka ottaisi huomioon sen, että toimintatavan omaksumisessa menee hetki, on kasvu silti merkittävä. Tämä luo painetta kohdeyrityksen omien toimintojen priorisoinnissa, etenkin koneistuksessa ja kokoonpanossa. Tuleekin pohtia, mikä on eskalointipyynnön perimmäinen tarkoitus. Ovatko kaikki tilaukset eskaloinnin arvoisia? Mitä suurempi osa tilauksista eskaloidaan, saattaa se lieventää eskaloinnin ja priorisoinnin tehokkuutta.

Voitaisiinko määrittää rajat avainasiakkuuksien, tilauksen arvon tai muiden tärkeäksi koettujen attribuuttien perusteella? Tällä hetkellä mitään arviointikriteeristöä ei ole, joten pyynnön avaaminen on pääasiassa tilauksenhallitsijan arviointikyvyn varassa. Esimerkiksi Akyildiz et al. (2015) havainnollistavat artikkelissaan yksiselitteisen kriteeristön vaikutuksia asiakastilausten priorisointiin. Heidän mukaansa ihmiset ovat usein taipuvaisia pysymään mielipiteissään, vaikka uusia näkökulmia ja todisteita tulisi saataville, joten selkeä kriteeristö on systemaattisen päätöksenteon kannalta ehdottoman tärkeää.

Selkeän kriteeristön lisäksi myös eskalointipyyntöjen oikea-aikaisuus on tärkeää, sillä mitä aikaisemmin ongelmat huomataan, sen helpompi ne ovat usein ratkaista. Eskalointipyyntöjen avaajilla tulisi olla mahdollisimman reaaliaikainen tieto tilauksen materiaalien sekä komponenttien aikataulusta saatavillaan. Periaatteessa heillä on kyseinen tieto saatavilla täysin reaaliajassa, mutta kaikkien tilausten seuraaminen viikoittain, tai jopa useammin ei ole mahdollista. Siksi yhtenä toimenpide-ehdotuksena on tilaustenhallitsijoille suunniteltu hälytysjärjestelmä, joka ilmoittaa tilauksen aikatauluun liittyvät muutokset välittömästi esimerkiksi sähköpostin välityksellä. Täten toimenpiteiden suunnittelu voitaisiin aloittaa mahdollisimman ajoissa. Yhdessä selkeän kriteeristön kanssa eskalointipyyntöjen avaamisesta tulisi yhä systemaattisempaa.

Toinen itse eskalointiprosessiin liittyvä ongelma oli, että tuotannonsuunnittelulle ensimmäisenä avatuissa pyynnöissä kysyttiin jonkin asian vapauttamista tuotantoon, vaikka siinä oli osapuute tai revisio kesken. Tämä tapahtui yhteensä 11 % pyynnöistä. Tämän kaltaiset pyynnöt lisäävät tarpeettomia keskusteluja, sillä kysyjä voisi itse tarkastaa sekä osapuutteen, että revision käytössä olevista järjestelmistä. Yksinkertainen ratkaisu tämän ongelman minimoimiseksi on korostaa huolellisuutta taustatietojen selvittämisessä.

Kolmas prosessiin liittyvä kyseenalaistus on se, että esimerkiksi kokoonpanoon liittyvistä keskusteluista 94 % olivat muotoa ”Milloin valmis?”. Samanlainen trendi oli havaittavissa myös esimerkiksi etenkin koneistuksen, mutta myös uudelleentyöstön parissa. Kohdeyrityksellä on kuitenkin useampia tietojärjestelmiä käytössään, joten ovatko kaikki manuaaliset varmistukset valmistumisesta tarpeellisia? Valmistumispäivämäärät ovat saatavilla toiminnanohjausjärjestelmästä, mutta ilmeisesti ne eivät ole riittävän luotettavia, jotta edellä mainittuihin kysymyksiin ei olisi tarve turvautua.

Seuraavaksi käsitellään toiminnoille tyypillisiä ongelmia. Ensimmäinen käsiteltävä toiminto on hankinta. Hankintaan liittyvät ongelmat voitiin jakaa Valmetista johtuviin syihin ja toimittajista johtuviin syihin, joiden suhdetta ei voitu juurisyybotin avulla tarkasti määrittämään, sillä keskusteluissa ei ollut kovinkaan usein mainintaa siitä. Toimittajista johtuvat syyt ovat kuitenkin merkittävä ja tiedossa oleva ongelma, johon pyrittiin löytämään ratkaisua myös kirjallisuudesta. Esimerkiksi Forslund & Mattson (2021) korostivat artikkelissaan kommunikoinnin tärkeyttä ja muutosten viestimistä välittömästi. Henry Xu (2020) ehdotti toimittajan ja asiakkaan väliseen kommunikointiongelmaan käytännönläheiseksi ratkaisuksi liikennevalomallia, joka automaattisesti ilmoittaa asiakkaalle mahdollisesta myöhästymästä: Vihreä valo kuvastaa normaalitilannetta, keltaisen valon aikaan tilaus ei ole edennyt normaalissa tahdissa, mutta myöhästymä on kurottavissa ja punainen valo näyttää, kun tilaus on selkeästi myöhässä. Hänen mukaansa korjaavien toimenpiteiden aloittamisen automatisointi sekä selkeiden parametrien määrittäminen vähentävät ihmisen havainnointikyvyn merkitystä. Tämä nopeuttaa toimenpiteiden käynnistämistä ja vähentää lopulta kokonaismyöhästymää. Myös koneistusta tarkasteltaessa merkittävimmät syyt liittyivät kapasiteettiin sekä ostettaviin materiaaleihin. Mikäli hankittavat materiaalit saataisiin nykyistä paremmin tehtaan käyttöön, olisi tuotannon joustavuus sekä kyky reagoida muuttuvaan tarpeeseen selkeästi parempi.

Uudelleentyöstöön liittyvän kategorisoinnin seurauksena yksi merkittävimmistä kategorioista oli revision seurauksena tehdyt muutokset, joka kattoi 17 % tapauksista. Revisioiden seurauksena tehtyjen muutosten suuri osuus voi selittyä asiakkaiden tarpeen muutoksella, mutta voidaan myös pohtia, onko myynti- ja tarjousvaiheessa tilauksen määrittelyssä täsmentämisen varaa. Mitä tarkemmin suunnittelutyö tehdään, sen sujuvampi on tuotantoprosessi. Myös Fortes et al. (2023) nostavat taulukossaan esille kilpailukyvyn keskeisiksi tekijöiksi tarjousten huolellisen laatimisen, tilausmuutokset ja konfigurointiprosessin. Kun tarkastelun kohteena oli kaikki uudelleentyöstöluokat suhteessa venttiilityyppeihin, oli jokaisen luokan kärjessä toistuvasti samat venttiilit eli A-sarjan tuotteet, joiden ongelmia tulisi tarkastella mielestäni tarkemmin, jotta toistuvat uudelleentyöstöongelmat saataisiin minimoitua.

5.3 Tutkimuksen rajoitteet ja jatkotutkimuskohteet

Tämä tutkimus keskittyi kriittisten asiakastilausten eskalointiprosessin analysointiin ja erityisesti suurten kielimallien käyttöön vapaamuotoisen tekstiaineiston jäsentämisessä. Vaikka tutkimus tarjosi uusia näkökulmia ja työkaluja prosessin kehittämiseen, siihen liittyy tiettyjä rajoitteita, jotka tulee ottaa huomioon.

Tutkimuksen aineiston rajallisuus voi vaikuttaa sen yleistettävyyteen. Kerätty aineisto perustui yhden yrityksen eskalointiprosessiin, mikä saattaa rajoittaa tulosten sovellettavuutta laajemmin eri toimialoilla tai erikokoisissa yrityksissä. Toinen huomioon otettava yksityiskohta on, että suurten kielimallien hyödyntäminen vaatii edelleen validointia ja tarkempaa analyysiä, jotta niiden tarjoamat tulokset voidaan varmistaa luotettaviksi. Kielimallit voivat tarjota kattavan analyysin suurista tietomassoista, mutta niiden kyky ymmärtää kontekstisidonnaisia erityispiirteitä vaatii laadukkaampaa hienosäätöä. Kolmanneksi tutkimuksessa keskityttiin ensisijaisesti eskalointiprosessin reaktiiviseen analyysiin. Jatkossa olisi suositeltavaa tutkia myös ennakoivan eskalointimallin mahdollisuuksia, esimerkiksi koneoppimisen ja kehittyneiden analytiikkatyökalujen avulla. Ennakoivan mallin avulla voitaisiin tunnistaa mahdolliset ongelmat ja haastavat konfiguraatiot tehokkaammin ennen niiden eskaloitumista ja siten parantaa koko toimitusketjun tehokkuutta.

Yksi mahdollinen jatkotutkimuksen suunta on myös suurten kielimallien laajempi integrointi toimitusketjun hallintaan, mikä voisi tarjota uusia keinoja datan analysointiin ja eskalointiprosessien optimointiin. Toiseksi tutkimuksen laajentaminen eri yrityksiin ja toimialoihin auttaisi arvioimaan esitettyjen menetelmien yleistettävyyttä ja skaalautuvuutta. Kolmanneksi eskalointiprosessin automatisointi yhdistämällä suuria kielimalleja ja perinteisiä ERP- ja MES-järjestelmiä voisi mahdollistaa tehokkaamman ja reaaliaikaisemman eskalointitietojen käsittelyn.

Jatkotutkimusta voitaisiin kohdistaa myös hankintaan sekä toimittajista johtuvien ongelmien syvempään analysointiin. Erityisesti olisi hyödyllistä selvittää, juontuvatko ongelmat toimittajien sisäisistä prosesseista, ulkoisista tekijöistä vai toimittajan ja asiakkaan välisen kommunikaation puutteista. Tämän tutkimuksen rajoitteena oli keskusteluaineiston heikko laatu hankinnan näkökulmasta, minkä vuoksi syvällisempi tarkastelu ei ollut mahdollista toivotulla tasolla.

Kaiken kaikkiaan tutkimus avasi uusia näkökulmia asiakastilausten eskalointiprosessiin ja osoitti, että suurilla kielimalleilla on potentiaalia liiketoiminnan analyysityökaluna. Lisätutkimusta tarvitaan erityisesti niiden soveltuvuuden varmistamiseksi erilaisissa toimintaympäristöissä ja integraatioissa muiden digitaalisten järjestelmien kanssa.

Lähteet

Abbass, H. (2021) Editorial: What is Artificial Intelligence? IEEE transactions on artificial intelligence. 2 (2), s. 94–95.

Adrodegari, F. et al. (2015) Engineer-to-order (ETO) production planning and control: an empirical framework for machinery-building companies. Production planning & control. 26 (11), s. 910–932.

Akyildiz, B. et al. (2015) A decision framework proposal for customer order prioritization: A case study for a structural steel company. International journal of production economics. 16921–30.

Amaratunga, T. (2023) Understanding Large Language Models: Learning Their Underlying Concepts and Technologies. 1st edition. Berkeley, CA: Apress.

Arslan, M. et al. (2024) Business insights using RAG–LLMs: a review and case study. Journal of decision systems. s. 1–30.

Balakrishnan, N., Sridharan, V. & Patterson, J.W., (1996) Rationing capacity between two product classes. Decision Sciences, 27(2), s.185-214.

Barut, M. & Sridharan, V., (2005). Revenue management in order-driven production systems. Decis. Sci. 36 (2), s. 287–316.

Benioudakis, M. et al. (2021) Lead-time quotations in unobservable make-to-order systems with strategic customers: Risk aversion, load control and profit maximization. European journal of operational research. 289 (1), s. 165–176.

Chen, C.-S. et al. (2009) The capacity planning problem in make-to-order enterprises. Mathematical and computer modelling. 50 (9), s. 1461–1473.

Chen, X. et al. (2012) Composite dispatching rule design for dynamic scheduling with customer-oriented production priority control. IEEJ transactions on electrical and electronic engineering. 7 (1), s. 53–61.

Chen, Y.-J. & Deng, M. (2015) Information Sharing in a Manufacturer-Supplier Relationship: Suppliers' Incentive and Production Efficiency. Production and operations management. 24 (4), s. 619–633.

Chopra, S. & Sodhi, M. S. (2004) Managing Risk to Avoid Supply-Chain Breakdown. MIT Sloan management review. 46 (1), s. 53-69.

Dwivedi, Y.K., et al. (2023), "So what if ChatGPT wrote it? Multidisciplinary perspectives on opportunities, challenges, and implications of generative conversational AI for research, practice and policy", International Journal of Information Management, Vol. 71, 102642, [Verkkodokumentti] [Viitattu 20.2.2025] Saatavissa doi: 10.1016/j.ijinfomgt.2023.102642.

Eloundou, T. et al. (2023) GPTs are GPTs: An Early Look at the Labor Market Impact Potential of Large Language Models. [Verkkodokumentti] [Viitattu 20.1.2025] Saatavissa doi: arXiv.org.

European parliament. 2022. Mitä tekoäly on ja mihin sitä käytetään? [Verkkodokumentti] [Viitattu 15.12.2024] Saatavissa: https://www.europarl.europa.eu/topics/fi/article/20200827STO85804/mita-tekoaly-on-ja-mihin-sita-kaytetaan#:~:text=Teko%C3%A4lyll%C3%A4%20tarkoitetaan%20koneen%20kyky%C3%A4%20k%C3%A4ytt%C3%A4%C3%A4,%2C%20oppimista%2C%20suunnittelemista%20tai%20luomista.

Felten, E.W., Raj, M. and Seamans, R. (2023), “How will language modelers like ChatGPT Affect occupations and industries?”, SSRN Electron Journal, [Verkkodokumentti] [Viitattu 15.12.2024] Saatavissa doi: 10.2139/ssrn.4375268.

Forslund, H. & Mattsson, S.-A. (2021) Strategies for achieving customer order flexibility – supplier perspective. Journal of manufacturing technology management. 32 (9), s. 396–413.

Fortes, C. S. et al. (2023) Engineer-to-Order Challenges and Issues: A Systematic Literature Review of the manufacturing industry. Procedia computer science. 2191727–1734.

Graham, A. K. (2000) Beyond PM 101: Lessons for Managing Large Development Programs. Project management journal. 31 (4), s. 7–18.

Gligor, D. (2018), “Performance implications of the fit between suppliers’ flexibility and their customers’ expected flexibility: a dyadic examination”, Journal of Operations Management, Vols 58-59, s. 73-85.

Gödri, I. (2024) An Escalation System for Handling and Analyzing Production Disturbances. Periodica polytechnica. Mechanical engineering - Mašinostroenie. 68 (2), s. 141–148.

Gosling, J. & Naim, M. M. (2009) Engineer-to-order supply chain management: A literature review and research agenda. International journal of production economics. 122 (2), s. 741–754.

Goswami, S. et al. (2013) A comparative analysis of information visibility in two supply chain management information systems. Journal of enterprise information management. 26 (3), s. 276–294.

Handayani, Dwi. (2018). Risk Management Of Supplier-Buyer In Procurement Of Raw Materials For Improving Supply Chain Performance. Jurnal Manajemen. 22. 293. [Verkkodokumentti] [Viitattu 12.1.2025] Saatavissa doi: 10.24912/jm.v22i3.423.

Hicks, C. et al. (2000) Supply chain management: A strategic issue in engineer to order manufacturing. International journal of production economics. 65 (2), s. 179–190.

Hsu, C. et al. (2008) Information sharing, buyer-supplier relationships, and firm performance: A multi-region analysis. International journal of physical distribution & logistics management. 38 (4), s. 296–310.

Hung, Y.F., Lee, T.Y., 2010. Capacity rationing decision procedures with order profit as a continuous random variable. Int. J. Prod. Econ. 125 (1), s. 125–136.

Husejnagić, D. and Sluga, A. (2015) "A conceptual framework for a ubiquitous autonomous work system in the Engineer-To-Order environment," , Int J Adv Manuf Technol, Article vol. 78, no. 9-12, s. 1971-1988, [Verkkodokumentti] [Viitattu 10.1.2024] Saatavissa doi: 10.1007/s00170-015-6798-7.

Kanike, Uday. (2023). Factors disrupting supply chain management in manufacturing industries. 4. , [Verkkodokumentti] [Viitattu 10.1.2024] Saatavissa doi: 10.18757/jscms.2023.6986.

Kouvelis, P. & Tang, S. Y. (2012) On Optimal Expediting Policy for Supply Systems with Uncertain Lead-Times. Production and operations management. 21 (2), s. 309–330.

Kucharavy, A. et al. (2024) Large Language Models in Cybersecurity : Threats, Exposure and Mitigation. 1st ed. 2024. Cham: Springer Nature Switzerland., 249 s.

Kumar, P. and Singh, A.P. (2020), “Flexibility in service operations: review, synthesis and research agenda”, Benchmarking: An International Journal, Vol. 27 No. 7, s. 2108-2129.

Laaksonen, S-M. (2023). Tekstiä tuottava tekoäly ja tieteen avoimuus. [Internet-sivut] [viitattu 23.10.2024] Saatavissa: https://blogs.helsinki.fi/thinkopen/tekoaly-ja-tieteen-avoimuus

Leng, M. & Parlar, M. (2009) Lead-time reduction in a two-level supply chain: Non-cooperative equilibria vs. coordination with a profit-sharing contract. International journal of production economics. 118 (2), s. 521–544.

Li, Y. et al. (2024) Large Language Models for Manufacturing. arXiv.org.
Liebowitz, J (ed.) 2020, Data Analytics and AI, Auerbach Publishers, Incorporated, Milton. [Verkkodokumentti] [Viitattu 10.1.2024] Saatavissa: ProQuest Ebook Central.

Lu, J. et al. (2024) Evaluation of large language models (LLMs) on the mastery of knowledge and skills in the heating, ventilation and air conditioning (HVAC) industry. Energy and built environment.

Lyneis, J. M. & Ford, D. N. (2007) System dynamics applied to project management: a survey, assessment, and directions for future research. System dynamics review. 23 (2-3), s. 157–189.

Mann, C. J. H. (2004) Systems Thinking – Creative Holism for Managers. Kybernetes, Vol. 33 No. 8.: [Verkkodokumentti] [Viitattu 19.1.2024] Saatavissa doi: org.ezproxy.cc.lut.fi/10.1108/k.2004.06733hae.001

Martino, A. et al. (2023) ‘Knowledge Injection to Counter Large Language Model (LLM) Hallucination’, in The Semantic Web: ESWC 2023 Satellite Events. Switzerland: Springer. s. 182–185.

Mello, M. H. et al. (2017) Improving coordination in an engineer-to-order supply chain using a soft systems approach. Production planning & control. 28 (2), s. 89–107.

Mishra, A. (ed.) (2023) Artificial intelligence and hardware accelerators. 1st ed. 2023. Cham, Switzerland: Springer Nature Switzerland AG.

Moore, R. 2007. Selecting the Right Manufacturing Improvement Tools. Oxford: Butterworth-Heinemann. 416 s.

Oberdorf, F. et al. (2021) Analytics-enabled escalation management: System development and business value assessment. Computers in industry. [Verkkodokumentti] [Viitattu 20.11.2024] Saatavissa doi: 131103481-.

Otegui, J. L. 2014. Failure Analysis – Fundamentals and Applications in Mechanical Components. Cham: Springer. 313 s.

Patterson, J. W., Balakrishnan, N. and Sridharan, V. (1997) 'An experimental comparison of capacity rationing models', International Journal of Production Research, 35(6), s. 1639–1650. [Verkkodokumentti] [Viitattu 20.10.2024] Saatavissa doi: 10.1080/002075497195173.

Pekgün, P. et al. (2017) Centralized versus Decentralized Competition for Price and Lead-Time Sensitive Demand. Decision sciences. [Verkkodokumentti] 48 (6), s. 1198–1227.

Pereira, D. F. et al. (2020) Tactical sales and operations planning: A holistic framework and a literature review of decision-making models. International journal of production economics. [Verkkodokumentti] [Viitattu 20.11.2024] Saatavissa doi: 228107695-.

Pereira, D. F. et al. (2022) Merging make-to-standardi/make-to-order decisions into sales and operations planning: A multi-objective approach. Omega (Oxford). [Verkkodokumentti] [Viitattu 20.11.2024] Saatavissa doi: 107102561-.

Pingjuan H. et al. (2005) Order scheduling problems in make-to-order manufacturing systems', in IEEE International Conference Mechatronics and Automation, 2005. 2005 IEEE. s. 2179-2184 Vol. 4.

Pollock, J. & Richardson, B. (2006) Using `Locked Wafers' to Prioritize Factory Resources', in 2006 IEEE International Symposium on Semiconductor Manufacturing. 2006 IEEE. s. 471–474.

Sarkar, B. et al. (2022) A three-echelon green supply chain management for biodegradable products with three transportation modes. Computers & industrial engineering. [Verkkodokumentti] [Viitattu 28.11.2024] Saatavissa doi: 174108727-.

Sawik, T. (2011) Selection of a dynamic supply portfolio in make-to-order environment with risks. Computers & operations research. 38 (4), s. 782–796.

Sedkaoui, S. & Benaichouba, R. (2024) Generative AI as a transformative force for innovation: a review of opportunities, applications and challenges. European journal of innovation management [Verkkodokumentti] [Viitattu 20.11.2024] Saatavissa: https://www-emerald-com.ezproxy.cc.lut.fi/insight/content/doi/10.1108/ejim-02-2024-0129/full/html

Seth, D. & Rastogi, S. (2019) Application of vendor rationalization strategy for manufacturing cycle time reduction in engineer to order (ETO) environment: A case study. Journal of manufacturing technology management. 30 (1), s. 261–290.

Shen, Y., Heacock, L., Elias, J., Hentel, K. D., Reig, B., Shih, G., & Moy, L. (2023). ChatGPT and Other Large Language Models Are Double-edged Swords. Radiology, 307(2), e230163.

Shin, N., Park, S. H., & Park, S. (2019). Partnership-Based Supply Chain Collaboration: Impact on Commitment, Innovation, and Firm Performance. Sustainability, 11(2), 449. [Verkkodokumentti] [Viitattu 21.12.2024] Saatavissa: https https://doi.org/10.3390/su11020449

Tanrisever, F. et al. (2012) Managing capacity flexibility in make-to-order production environments. European journal of operational research216 (2), s. 334–345.

Taulli, T. Generative AI: How ChatGPT and Other AI Tools Will Revolutionize Business. 1st ed. Berkeley, CA: Apress, 2023.

Törnberg, P. (2023) How to use LLMs for Text Analysis. [Verkkodokumentti] [Viitattu 20.11.2024] Saatavissa: arXiv.org.

Valmet (2025) Virtauksensäätö-liiketoimintalinja. [Internet sivut] [viitattu 23.12.2024] Saatavissa: https://www.valmet.com/fi/sijoittajat/valmet-sijoituskohteena/liiketoimintalinjat/flow-control/

Verspoor, K. (2024) ‘Fighting fire with fire’ — using LLMs to combat LLM hallucinations. Nature (London). 630 (8017), s. 569–570.

Viswanath, K. (2024) PROMPTING LLMs. MIT Sloan management review. 65 (4), s. 7.

Wach, K., Duong, C.D., Ejdys, J., Kazlauskaite, R., Korzynski, P., Mazurek, G., Paliszkiewicz, J. and Ziemba, E. (2023), “The dark side of generative artificial intelligence: a critical analysis of controversies and risks of ChatGPT”, Entrepreneurial Business and Economics Review, Vol. 11 No. 2, s. 7-30, [Verkkodokumentti] [Viitattu 2.11.2024] Saatavissa doi: 10.15678/eber.2023.110201.

Wagner, S.M., Grosse-Ruyken, P.T. and Erhun, F. (2018), “Determinants of sourcing flexibility and its impact on performance”, International Journal of Production Economics, Vol. 205, s. 329-341.

Wang, J., Yang, J.Q. & Lee, H., (1994) Multicriteria order acceptance decision support in over-demand job shops: a neural network approach. Math. Comput. Model. 19 (5), s. 1–19.

Wu, I.-L. et al. (2014) Information sharing and collaborative behaviors in enabling supply chain performance: A social exchange perspective. International journal of production economics. S. 122–132.

Xu, H. (2020) Minimizing the ripple effect caused by operational risks in a make-to-order supply chain. International journal of physical distribution & logistics management. 50 (4), 381–402.

Zhang, C. et al. (2024) ‘FinSQL: Model-Agnostic LLMs-based Text-to-SQL Framework for Financial Analysis’, in Companion of the 2024 International Conference on Management of Data. 2024 New York, NY, USA: ACM. s. 93–105.

Zhao, C. et al. (2023) ‘Differentiable Retrieval Augmentation via Generative Language Modeling for E-commerce Query Intent Classification’, in Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. 2023 New York, NY, USA: ACM. s. 4445–4449.

Zheng, S., Huang, J. and Chang, K.C.-C. (2023) Why does chatgpt fall short in providing truthful answers. [Verkkodokumentti] [Viitattu 21.1.2024] Saatavissa: https://arxiv.org/abs/2304.10513

Zhou, B. et al. (2024) CausalKGPT: Industrial structure causal knowledge-enhanced large language model for cause analysis of quality problems in aerospace product manufacturing. Advanced engineering informatics. [Verkkodokumentti] [Viitattu 20.11.2024] Saatavissa doi: 5910233

Zhou, H. & Benton, W. C. (2007) Supply chain practice and information sharing. Journal of operations management. 25 (6), s. 1348–1365.

Zhou, J. et al. (2018) Human and Machine Learning Visible, Explainable, Trustworthy and Transparent. Cham: Springer International Publishing.

Zhou, Y. et al. (2022) A system dynamics archetype to mitigate rework effects in engineer-to-order supply chains. International journal of production economics. [Verkkodokumentti] [Viitattu 20.11.2024] Saatavissa doi: 250108620-

Liite 1: Juurisyytutkimuskehote kielimallille

Assistentin Ohjeistus: Juurisyiden Selvittäminen

1. **Tehtäväsi**: Analysoi keskusteludataa ja selvitä keskustelun aloituksen juurisyy tai juurisyyt. Keskity erityisesti aikaleimallisesti vanhimpiin kommentteihin.

2. **Vastausmuoto**:

- Anna arvio juurisyystä muodossa: "1. Juurisyy:... 2. Juurisyy... jne."
- Listaa niin monta syytä, kuin kyseinen keskustelu edellyttää.
- Jos venttiilin osa on juurisyy, käytä muotoa: "Venttiilin osiin liittyvä ongelma: *[Nimeä osat]*". Selvitä, onko osa myöhässä toimittajalta vai viallinen (rework). Mainitse tarkasti, mikä osa aiheutti ongelman (pesä, läppä, pallo, tiiviste, tai muu).

6. **Käytäntöjä**:

- Segmenttien korjaus = rework
- Venttiili vuotaa = rework
- Osa tulossa x.xx.xxxx = Osa tulossa myöhässä
- MO XXXXXXXXXX = Kerro, että kyseinen osa tuotannossa

Tyypillisiä venttiilin osia ovat pesä (Body), Tiiviste (seat), pallo (ball), drive shaft, shaft, läppä (disc) sekä tyypillisiä komponentteja ovat rajakytkin (limit switch = mankku), toimilaite (actuator) ja venttiilin ohjainlaite (valve controller). Venttiilin tuotantoprosessi alkaa rikastuksesta, siirtyen venttiilin osien ostamiseen (purchasing), josta siirrytään osien jatkojalostamiseen koneistamalla, jonka jälkeen siirrytään venttiilien kokoonpanoon, sitten FATiin (=lopputarkastus), ja sitten pakkaamiseen. Mikäli jossain kohtaa tulee ongelmia. Venttiili tai sen osa siirretään reworkiin jossa korjaavat toimenpiteet tehdään.

Pidä vastaukset tiiviinä ja karsi turhat sanat, jotta vastaukset ovat helposti kategorisoitavissa.

Liite 2: Juurisyykategorialista:

Juurisyykategoria
Venttiilin osan aikatauluongelmat
Venttiilin osan laatuongelmat
Komponenttien laatuongelmat
Komponenttien aikatauluongelmat
Uudelleentyöstö ja korjaustarpeet
Suunnittelu- ja rakennevirheet
Asiakkaan vaatimus aikaista alkuperäisestä toimituspäivästä tai projekinhallinta haluaa varmistaa toimituksen
Toimittajan tai alihankkijan laatuongelmat
Toimittajan tai alihankkijan aikatauluongelmat
Koneistuksen kapasiteettihaasteet
Koneiden huollot ja rikkoutumiset
Maalaus- ja pinnoitusongelmat
Dokumentaatio, asiakirja tai tokari ei saatavilla (NACE, ATEX, atex, mittakuva, instrukuva, qplan, tokaripaketti)
Keräily- ja kokoonpanohaasteet
Testaus- ja hyväksyntäprosessin nopeuttamistarve
Kuljetusmuodon muutokset (merirahdista lentorahdiksi)
Satamaruuhkat ja ulkoiset logistiset haasteet (esim. Tulli)
Asiakastyytyväisyyden ja eskalaatioiden hallinta
Revisiosta seuranneet viivästykset ("revisio" mainittava)
Kysytään prosessin edistymistä
Force majeure
Asennus- ja kokoonpanovirheet (uudelleentyöstö)
Koneistus- ja pinnoitusvirheet
Ongelmat pesän tai bodyn aikataulussa
Ongelmat pallon aikataulussa
Ongelmat tiivisteen tai seatin aikataulussa
Ongelmat pesän tai bodyn laadussa
Ongelmat pallon laadussa
Ongelmat tiivisteen tai seatin laadussa
Ongelmat segmentin laadussa
Ongelmat segmentin aikataulussa
Ongelmat läpän tai discin laadussa
Ongelmat läpän tai discin aikataulussa
Ventiilin vuoto-ongelma
Pinnoitusongelmat (uudelleentyöstö)
Vastaanoton ja tarkastuksen, ja lopputarkastuksen (eli FAT ja FIT) priorisointi
Hitsausvaatimukset
Väärin mitoitetut osat
Osaa ei ole ostettu, se on mennyt toiselle tilaukselle tai ostotilaus puuttuu
Varastosaldo ei pidä paikkaansa
Työntekijän sairausloma tai lomautus
Ongelmat bonnetin laadussa
Ongelmat bonnetin aikataulussa
Pyydetään kiireellistä pakkausta
Ongelmat body capin laadussa
Ongelmat body capin aikataulussa