

Petrus Seppälä

TEKOÄLYN HYÖDYNTÄMINEN KYSYNNÄN ENNUSTAMISESSA

Kandidaatintyö
Johtamisen ja talouden tiedekunta
Tarkastaja: Jussi Valta
Toukokuu 2025

TIIVISTELMÄ

Petrus Seppälä: Tekoälyn hyödyntäminen kysynnän ennustamisessa (Utilizing Artificial Intelligence in Demand Forecasting)

Kandidaatintyö

Tampereen yliopisto

Tuotantotalous

Toukokuu 2025

Tekoälyn hyödyntäminen kysynnän ennustamisessa on yleistynyt, ja siihen liittyvien tutkimusten määrä on kasvanut viime vuosina. Kysynnän ennustamisella on keskeinen rooli nykyaikaisessa liiketoiminnassa ja toimitusketjun hallinnassa, ja sen tarkkuus on ratkaisevaa esimerkiksi yrityksen päätöksenteossa. Tämän kandidaatintyön tarkoituksena on lisätä ymmärrystä siitä, kuinka tekoälyä pystytään hyödyntämään kysynnän ennustamisessa verrattuna perinteiseen ennustamiseen.

Tämä kandidaatintyö toteutettiin kirjallisuuskatsauksena hyödyntäen pääsääntöisesti tietolähteenä Scopusta. Työn ensimmäinen osa on johdanto, jonka jälkeen seuraavissa kahdessa luvussa esitetään työn aiheeseen liittyvä teoria. Teoriaosiossa määritellään relevantit käsitteet sekä taustoitetaan työlle oleelliset näkökulmat. Neljännessä luvussa käsitellään työn tulokset ja vastataan johdannossa esitettyihin tutkimuskysymyksiin. Lopuksi tulokset on koostettu päätelmiksi, jotka esitetään työn viimeisessä eli viidennessä luvussa.

Työssä havaittiin, että tekoälypohjaisia ratkaisuja hyödynnetään huomattavasti enemmän määrällisessä kuin laadullisessa ennustamisessa. Kuitenkin kirjallisuuden perusteella ei voida todeta, että määrällinen ennustaminen olisi parempi vaihtoehto kuin laadullinen. Ei ole olemassa yhtä tiettyä ennustamisen mallia, joka toimisi jokaisessa tilanteessa. Jotta voidaan valita oikea ennustamisen malli kullekin tilanteelle, täytyy ymmärtää ennustamisen tilanteessa käytetty konteksti. Ennustamisessa tulee onnistua, jotta voidaan minimoida epätarkoista ennusteista johtuvat kustannukset.

Avainsanat: Tekoäly, koneoppiminen, kysynnän ennustaminen, määrällinen ennustaminen, laadullinen ennustaminen

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin Originality Check -ohjelmalla.

TEKOÄLYN KÄYTTÖ OPINNÄYTTEESSÄ

Opinnäytteessäni on käytetty tekoälysovelluksia:

- Ei
- Kyllä

Ilmoitukseni mukaan olen käyttänyt opinnäytteessäni tutkielmaprosessin aikana seuraavia tekoälysovelluksia:

Tekoälysovellusten nimet ja versiot: ChatGPT-4o

Käyttötarkoitus: ChatGPT-4o tekoälysovellusta on käytetty työssä omien ideoiden jalostamiseen. Tekoälyä hyödynnettiin työn rakenteen suunnittelussa omien ideoiden sekä seminaareista saatujen palautteiden pohjalta. Tekoälyä käytettiin myös englanti-suomi-käännöstyökaluna englanninkielisten tieteellisten artikkelien pohjalta.

Osiot, joissa tekoälyä on käytetty: Kaikissa osioissa

Olen tietoinen siitä, että olen täysin vastuussa koko opinnäytteeni sisällöstä, mukaan lukien osat, joissa on hyödynnetty tekoälyä, ja hyväksyn vastuun mahdollisista eettisten ohjeiden rikkomuksista.

SISÄLLYSLUETTELO

1.	JOHDANTO.....	1
1.1	Työn tausta.....	1
1.2	Tutkimuskysymykset.....	2
1.3	Tutkimusmetodologia.....	2
1.4	Työn rakenne	5
2.	KYSYNNÄN ENNUSTAMISEN PERUSTEET.....	6
2.1	Kysynnän ennustaminen.....	6
2.2	Ennustamisen prosessi	7
2.3	Hyvän ennusteen kriteerit	8
2.4	Kysynnän ennustamisen menetöt.....	10
2.5	Kysynnän ennustamisen mittaaminen	11
3.	TEKOÄLYN ROOLI KYSYNNÄN ENNUSTAMISESSA.....	13
3.1	Koneoppiminen.....	13
3.2	Haasteet ja riskit.....	15
4.	TEKOÄLYN KÄYTÄNNÖN HYÖDYT KYSYNNÄN ENNUSTAMISEN TYÖKALUNA	17
4.1	Tekoälyn soveltuvuus määrällisessä ennustamisessa.....	17
4.2	Tekoälyn soveltuvuus laadullisessa ennustamisessa	22
4.3	Tekoälyn ja ihmisen yhteistyö päätöksenteossa epävarmuuden vallitessa	23
5.	PÄÄTELMÄT.....	25
	LÄHTEET	28

1. JOHDANTO

1.1 Työn tausta

Kysynnän ennustamisella on keskeinen rooli nykyaikaisessa liiketoiminnassa. Se antaa tuottavalle teollisuudelle mahdollisuuden optimoida tuotantoprosesseja halliten tehokkaasti varastotasoja sekä täyttäen asiakkaiden tarpeita (Doanh et al., 2023). Kysynnän ennustaminen on yksi toimitusketjun perusongelmista, ja siinä täytyy onnistua, jotta voidaan taata sujuva toimitusketjun toiminta (Tadayonrad & Ndiaye, 2023). Mitä tarkempia ennusteet ovat, sitä paremmin suunnittelun ja päätöksenteon tulokset vastaavat organisaation vaatimuksia (Hsieh et al., 2019).

Ennustamisen teoria perustuu lähtökohtaan, jossa nykyistä ja mennyttä tietoa voidaan hyödyntää tekemällä ennusteita tulevaisuudesta (Petropoulos et al., 2022). Tekoäly voi parantaa päätöksentekoa ennusteiden perusteella organisaatioissa erityisesti analyttisellä lähestymistavalla. Tekoäly (Artificial Intelligence) pystyy käsittelemään suuria määriä dataa sekä tunnistamaan monimutkaisia suhteita, mikä auttaa ennustamaan kysyntää tarkasti. (Jarrahi, 2018) Tarkka kysynnän ennustaminen voi minimoida merkittävästi riskejä ja parantaa päätöksentekoa useilla eri sektoreilla, kuten terveydenhuollossa, IT-alalla ja energia-alalla (Petropoulos et al., 2022). Tässä työssä keskitytään tuottavan teollisuuden sektoriin.

Tekoälyyn lukeutuu monta eri menetelmää, joista koneoppiminen on yksi. Yritykset voivat hyötyä koneoppimisen algoritmeista esimerkiksi turvavarastojen tasojen optimoinnilla, sillä sen avulla voidaan hyödyntää suuria määriä dataa sekä muita muuttujia, kuten menneitä myyntejä. (Tadayonrad & Ndiaye, 2023) Tekoäly hyvin laajana käsitteenä on haastava tiivistää yksiselitteisesti (Jarrahi, 2018). Selkeyden vuoksi tässä työssä keskitytäänkin sen osa-alueeseen, koneoppimiseen. Irshadullahin et al. (2025) mukaan tekoäly on noussut liiketoiminnan muutosvoimaksi erityisesti tehokkuuden lisäämisessä ja toimitusketjun hallinnan optimoinnissa. Tekoälypohjaisia tekniikoita, kuten koneoppimista, on integroitu erilaisiin liiketoimintaprosesseihin parantamaan tuottavuutta, alentamaan kustannuksia ja tehostamaan päätöksentekoa (Irshadullah et al., 2025). Monet tutkijat ovat ilmaisseet koneoppimisen mukana tulevan potentiaalisen merkityksen ja odotuksen älykkään tuotannon saavuttamiseksi. Älykkään tuotannon suunnitteluun ja kehittämiseen ei kuitenkaan ole olemassa selkeää ohjenuoraa. (Oluyisola et al., 2022)

Tästä syystä työn aihe on erityisen mielenkiintoinen, ja työn tavoitteena on lisätä ymmärrystä siitä, kuinka tekoälyä pystytään hyödyntämään kysynnän ennustamisessa verrattuna perinteiseen ennustamiseen.

1.2 Tutkimuskysymykset

Tässä kandidaatintyössä perehdytään tekoälyn hyödyntämiseen kysynnän ennustamisen tarkkuuden parantamisessa. Tarkoituksena on tutkia, minkälaisia tietotarpeita ja vaatimuksia kysynnän ennustaminen vaatii. Lisäksi tarkoituksena on tutkia, minkälaisia vahvuuksia tekoälymenetelmillä, erityisesti koneoppimisella (Machine Learning), on tiedon tuottamisessa. Tässä työssä pohditaan myös tekoälypohjaisen kysynnän ennustamisen vaikutusta yrityksen resurssien käyttöön. Työn rungoksi valitut tutkimuskysymykset käsittelevät tekoälyä erityisesti sen hyödyntämisen näkökulmasta verraten normaaliin kysynnän ennustamiseen. Tämän työn tarkoituksena on löytää vastaus alla oleviin tutkimuskysymyksiin:

- 1) Millä tavoin koneoppimista voidaan hyödyntää kysynnän ennustamisessa?
- 2) Kuinka tekoälypohjainen kysynnän ennustaminen vaikuttaa yrityksen toimintaan ja sen resurssien käyttöön?

Edellä esitetyt tutkimuskysymykset muodostavat perustan tekoälyn roolin ja hyötyjen selvittämiseksi kysynnän ennustamisessa. Ensimmäinen kysymys keskittyy tekoälyn konkreettiseen hyödyntämiseen ennustamisen tarkkuuden parantamisessa, kun taas toinen tutkimuskysymys laajentaa näkökulmaa yrityksen kokonaistehokkuuteen ja resurssien hallintaan, mikä mahdollistaa laajemman arvioinnin tekoälyn hyödyllisyydestä kysynnän ennustamisessa. Näiden kysymysten avulla pyritään selvittämään, kuinka tekoäly voi tuoda lisäarvoa perinteisiin ennustamismenetelmiin verrattuna ja miten tämä potentiaali voidaan valjastaa yrityksen hyödyksi. Työssä pohditaan erityisesti koneoppimisen menetelmien kyvykkyyttä käsitellä suuria datamääriä ja tunnistaa monimutkaisia suhteita, jotka voivat johtaa tarkempiin kysynnän ennusteisiin ja siten tehostaa liiketoimintaa.

1.3 Tutkimusmetodologia

Tutkimusmetodina työn toteuttamisessa toimii tiedonhaku Scopuksesta. Scopuksessa suoritettulla tiedonhauulla on löytynyt aiheeseen liittyviä lähteitä muun muassa hakulauseella ("artificial intelligence" OR "machine learning") AND forecasting AND ("supply planning" OR "production planning"). Lisäksi haku rajattiin julkaisuvuosiin 2018–2025 sekä julkaisutyyppi artikkeliksi. Näillä rajauksilla hakutuloksia tuli 141. Hakulauseessa

esiintyy tuotannosuunnittelun käsite, sillä se liittyi työn rajaukseen. Kuitenkin työn rajaus muuttui vielä, kun tiedonhaku oli toteutettu ja useita kirjallisuuslähteitä valittu työhön. Tästä syystä kyseinen hakulauseke on pysynyt samana. Viime vuosina aiheesta on julkaistu valtava määrä artikkeleita, jolloin tiedonhaussa uusimmat julkaisuvuodet korostuvat hyvänä rajauksena. Rajauksen avulla löydetään relevantit lähteet suuresta joukosta. Edellä mainittuun lähdehakuun verraten hakemalla Scopuksesta “industry 4.0” AND “demand forecast”, saadaan 39 hakutulosta ja rajaamalla nämä tieteellisiin artikkeleihin, jää jäljelle 16 tulosta. Tästä määrästä on helppo löytää relevantit ja työhön sopivat lähteet lukemalla ensin tiivistelmät ja sen perusteella valitsemalla artikkelit, jotka luetaan kokonaan. Sähköisten tietolähteiden ohella työssä käytetään William J. Stevensonin kirjoittamaa ”Operations Management” -oppikirjaa. Lisäksi tässä kirjallisuuskatsauksessa on hyödynnetty helmenkasvatusmenetelmää (Schlosser et al., 2006), jossa lähdeaineistoa rikastutettiin tutkimalla alkuperäisten artikkeleiden lähteitä.

Kaikki tähän työhön valitut lähteet läpäisivät kriteerit, joissa käsiteltiin aihealueen keskeisiä käsitteitä ”Artificial intelligence”, ”Machine learning” ja ”Demand forecasting”. Tiedonhaussa rajausten jälkeen valinnan ulkopuolelle jääneet lähteet eivät läpäisseet näitä kriteerejä tai eivät olleet Julkaisufoorumin arvioimana vähintään 1. luokan artikkeleja. Tiedonhaku tähän tutkimusaiheeseen on näin ollen helposti toistettavissa. Taulukossa 1 on havainnollistettu tiedonhaun tuloksia työn tulososioon, sekä kyseisten artikkeleiden JUFO- luokituksia.

Taulukko 1: *Tulososioon valitut kirjallisuuslähteet*

Artikkeli	Viittaus	Journal	Jufo
The M4 Competition: Results, findings, conclusion and way forward	(Makridakis et al., 2018b)	International Journal of Forecasting	2
Statistical and Machine Learning forecasting methods: Concerns and ways forward	(Makridakis et al., 2018a)	<i>PLoS ONE</i>	1
A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting	(Smyl, 2020)	International Journal of Forecasting	2
Demand forecasting in the presence of systematic events: Cases in capturing sales promotions	(Abolgasemi et al., 2020)	International Journal of Production Economics	2
Demand forecasting tool for inventory control smart systems	(Benhamida et al., 2021)	Journal of Communications Software and Systems	1
Forecasting: theory and practice	(Petropoulos et al., 2022)	International Journal of Forecasting	2
Approaching sales forecasting using recurrent neural networks and transformers	(Vallés-Pérez et al., 2022)	Expert Systems with Applications	2
Artificial Intelligence and the Future of Work: Human-AI Symbiosis in Organizational Decision Making	(Jarrahi, 2018)	Business Horizons	1
Machine learning: Trends, perspectives, and prospects.	(Jordan & Mitchell, 2015)	Science	3
Predictive Analytics for Demand Forecasting – A Comparison of SARIMA and LSTM in Retail SCM	(Falatouri et al., 2022)	Procedia Computer Science	1
An optimized model using LSTM network for demand forecasting	(Abbasimehr et al., 2020)	Computers & Industrial Engineering	1
Demand prediction and price optimization for semi-luxury supermarket segment	(Qu et al., 2017)	Computers & Industrial Engineering	1

1.4 Työn rakenne

Tämä kandidaatintyö rakentuu kahdesta aiheeseen liittyvää teoriaa käsittelevästä luvusta sekä kolmannelta, tuloksia tarkastelevasta luvusta. Työn toinen luku aloittaa kaksi lukua kattavan teoriaosion. Ensimmäisessä teoriaa käsittelevässä luvussa keskitytään kysynnän ennustamisen perusteisiin. Luvussa esitetään peruskäsitteet kysynnän ennustamisesta, ennustamisen prosessista, hyvän ennusteen kriteereistä, kysynnän ennustamisen metodeista sekä sen mittaamisesta. Nämä teoriakappaleet ovat tärkeitä, jotta lukija ymmärtää työn varsinaiseen aiheeseen liittyvän kontekstin. Kolmannessa luvussa, eli toisessa teoriaa käsittelevässä luvussa, puolestaan käsitellään syvemmin tekoälyn, erityisesti koneoppimisen, roolia kysynnän ennustamisessa sekä pohditaan aiheeseen liittyviä haasteita ja riskejä. Koneoppimista käsittelevä luku antaa pohjan työn tuloksille.

Teorialuvut toimivat pohjana neljännelle luvulle, jossa käsitellään tuloksia. Luvussa pohditaan tulosten pohjalta, miten tekoäly soveltuu kysynnän ennustamiseen. Kyseisessä luvussa vastataan työn tutkimuskysymyksiin, jotka ovat esitettynä johdannossa. Tulossosiossa käsitellään kysynnän ennustamista erikseen sekä määrällisestä että laadullisesta näkökulmasta. Lisäksi pohditaan lähdekirjallisuuden perusteella ihmisen ja tekoälyn välistä toimintaa epävarmuuden vallitessa. Neljännän luvun jälkeen esitetään vielä työn päätelmät, joka toimii yhteenvetona koko työlle.

2. KYSYNNÄN ENNUSTAMISEN PERUSTEET

Tässä luvussa käsitellään kysynnän ennustamisen perusteita kirjallisuuden pohjalta. Näin ymmärretään paremmin konteksti, jonka kautta tekoälyä käsitellään. Kysynnän ennustamisen tarkastelun tukena käytetään prosessikaaviota, jotta ymmärretään, kuinka ennusteita luodaan. Perusteiden lisäksi esitetään tavallisesti käytettyjä ennustamisen metodeja. Laajemmassa käsittelyssä metodeista ovat yläkategoriat eli laadulliset ja määrälliset metodit. Tärkeä osa ennustamista on myös sen onnistumisen mittaaminen, joten viimeisessä alaluvussa käsitellään ennustamiseen liittyviä mittareita. Lisäksi hyvälle ennusteelle esitetään kriteerit, joilla sitä voidaan arvioida.

2.1 Kysynnän ennustaminen

Ennustaminen on kehittynyt valtavasti vuosisatojen aikana siitä, kun aikaisen vaiheen ihmiset katsoivat taivaalle ja ennustivat, onko sää sopiva metsästykseseen. He muodostivat ennustuksia, kuten: ”noin 50 % mahdollisuus sateeseen”. Nykyajan metsästäjä puolestaan voi katsoa puhelimestaan reaaliaikaisen ennustuksen lämpötiloista ja sadekar-toista monissa eri paikoissa samaan aikaan. (Petropoulos et al., 2022)

Perinteiset kysynnän ennustamisen tekniikat perustuvat pääasiassa aksioomiin, eli siihen, että historia toistaa itseään. Arvioita voidaan johtaa aikaisemmista myyntitrendeistä, jotka voivat riippua esimerkiksi vuodenaikojen vaihtelusta. Kuitenkin kysyntä riippuu todella monista muistakin tekijöistä, kuten ihmisten elintasosta, inflaatiosta, hinnasta, yrityksen julkisesta kuvasta ja palvelun laadusta. Jos nämä tekijät jätetään huomiotta, yritykset kohtaavat ongelmia, jotka liittyvät ylipursuaviin tai alhaisiin varastoihin, kesken-eräisiin tilauksiin, asiakkaiden tyytymättömyyteen tai varastojen loppumiseen. (Singh et al., 2023) Yritysten tuleekin löytää sopiva puskurivaraston taso vastaamaan asiakkaiden vaatimuksiin, samalla välttämällä ylipursuavan varaston ja siitä koituvat kustannukset (Tadayonrad & Ndiaye, 2023).

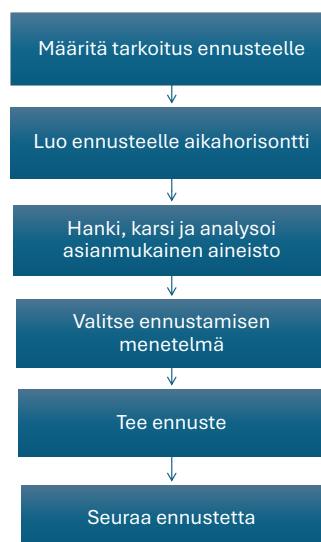
Kysynnän ennustamisella on keskeinen rooli nykyaikaisessa toimitusketjun hallinnassa. Se on pakollinen osa varastojen suunnittelua sekä hallintaa ja voi olla haastavaa ajoitel-len. Merkittävimpiä ongelmia kysynnän ennustamiseen liittyen ovat riittämätön ennus-teen tarkkuus sekä todellisen kysynnän vaihtelu, jotka johtavat ennustevirheisiin. (Singh et al., 2024) Tadayonradin & Ndiayen (2023) mukaan toimitusketjun järjestelmät ovat aina painineet tulevaisuuden kysynnän ennustamisen ongelman kanssa. Tarkan arvion avulla toimitusketjun työntekijät voivat tehdä parempia päätöksiä suunnittelussa ja ovat

valmiudessa tekemään päätöksiä käytännön prosesseissa (Tadayonrad & Ndiaye, 2023).

2.2 Ennustamisen prosessi

Ennustamisessa onnistuminen on todella tärkeä osa toimitusketjua. Epätarkat ennusteet voivat aiheuttaa puutteita tai ylitarjontaa koko toimitusketjussa. Materiaalin, osien tai palveluiden puute voi johtaa toimitusten myöhästymiseen, työn keskeytymiseen ja huonoon asiakaspalveluun. Liian optimistiset ennusteet voivat puolestaan johtaa materiaalien ja/tai kapasiteetin ylitarjontaan, mikä lisää kustannuksia. (Stevenson, 2015 s. 76–77) Nykyään liiketoimintavaihtojen ja ennustamisen tukena käytettäviä tietoja on helpompi kerätä ja tallentaa kuin koskaan aiemmin, koska tietotekniikka ja teknologia ovat kehittyneet valtavasti (Ahamed et al., 2023).

Toimitusketjun puutteet ja ylitarjonta vaikuttavat negatiivisesti asiakaspalvelun kautta asiakkaisiin sekä myös yrityksen rahallisiin voittoihin. Lisäksi epätarkat ennusteet voivat johtaa toimitusketjun tilausten tilapäiseen lisääntymiseen tai vähenemiseen, minkä toimitusketju voi tulkita väärin. Organisaatiot voivat vähentää tällaisten tapausten todennäköisyyttä monin tavoin. Yksi selkeimmistä keinoista tämän ongelman ratkaisuun on pyrkiä kehittämään parhaat mahdolliset ennusteet. (Stevenson, 2015 s. 76–77) Kysynnän ennustamiselle on kuusivaiheinen prosessi, jonka vaiheet ovat esitetty kuvassa 1.



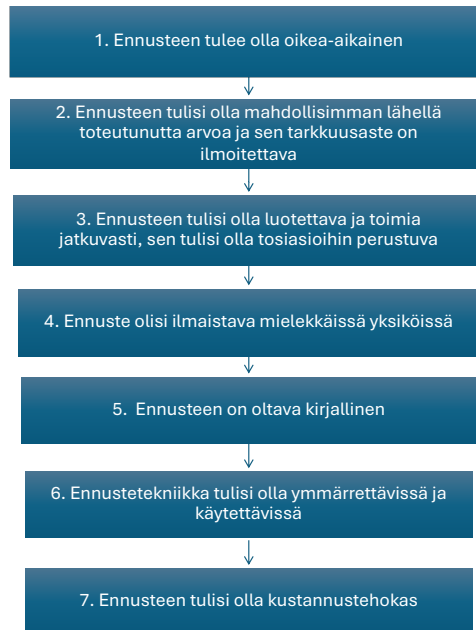
Kuva 1: Kysynnän ennustamisen prosessi (mukaillen lähteistä Stevenson, 2015 s. 73–131; Ahamed et al., 2023; Malviya & Bhandari, 2024)

Prosessin ensimmäinen vaihe selvittää, kuinka ennustetta käytetään ja milloin sitä tarvitaan. Tämä vaihe antaa indikaattorin tarvittavalle datalle sekä resursseille kuten henkilöstölle tai kustannuksille ennustetta varten. Myös ennusteen tarkkuus on tarpeellista selvittää prosessin ensimmäisessä vaiheessa. (Stevenson, 2015 s. 73–77; Malviya & Bhandari, 2024) Ennusteita tehdään, jotta niistä saatua informaatiota voidaan käyttää konkreettisin keinoin hyödyksi saavuttaakseen organisaation tavoitteita (Ahamed et al., 2023).

Prosessin toisessa vaiheessa ennusteelle pitää määrittää aikahorisontti, jossa tulee huomioida, että ennusteen tarkkuus laskee aikahorisontin kasvaessa. Aikahorisontti voi olla joko lyhyt, keskipitkä tai pitkä. (Ahamed et al., 2023) Stevensonin (2015) mukaan prosessin kolmannessa vaiheessa tulee huomioida, että tarvittavien tietojen hankkiminen voi vaatia huomattavia ponnisteluja. Kun tiedot on saatu, ne on ”puhdistettava”, jotta niistä voidaan poistaa poikkeavat ja ilmeiset virheelliset tiedot ennen analysointia. Näiden vaiheiden jälkeen valitaan ennustemalli ja tehdään ennuste. Tämän jälkeen ennustetta tulee tutkia, jotta ymmärretään antaako se tyydyttävän vastauksen tarpeisiin. Jos näin ei ole, on tarkasteltava uudelleen menetelmää, oletuksia tai tietojen pätevyyttä, muutettava niitä tarvittaessa ja laadittava tarkistettu ennuste optimaalisen suorituskyvyn saavuttamiseksi. (Stevenson, 2015 s. 73–77; Malviya & Bhandari, 2024)

2.3 Hyvän ennusteen kriteerit

Hyvän ennusteen kriteerit ovat olennaisia luodessa ja arvioitaessa liiketoiminnan ennustemalleja. *Kuvassa 2* tiivistetään nämä keskeiset ominaisuudet, jotka tekevät ennusteesta arvokkaan päätöksenteon tukipilarin. Ensimmäisenä kriteerinä esitetään, että ennusteen tulee olla oikea-aikainen. Oikea-aikaiset ennusteet mahdollistavat sen, että yritykset voivat reagoida tulevaan kysyntään riittävän ajoissa (Ahamed et al., 2023). Ennustehorisontin on katettava aika, joka tarvitaan mahdollisten muutosten toteuttamiseen, sillä esimerkiksi varastotasoja tai kapasiteettia ei voida muuttaa välittömästi (Stevenson, 2015 s. 76).



Kuva 2: Hyvän ennusteen kriteerit (mukailien lähteistä Stevenson 2015, s. 75–76; Ahamed et al., 2023)

Toisena kriteerinä ennusteen tulisi olla mahdollisimman lähellä toteutunutta arvoa, ja sen tarkkuusaste on ilmoitettava. Määrälliset virhemittarit, kuten kappaleessa 2.5 esitetty Mean Absolute Error (MAE), ovat välttämättömiä ennusteen tarkkuuden arvioinnissa. Hyvä ennustemalli pyrkii minimoimaan nämä virheet. (Ahamed et al., 2023) Kolmantena elementtinä ennusteen tulisi olla luotettava, toimia jatkuvasti ja olla tosiasioihin perustuva. Tekniikka, joka tuottaa joskus hyvän ja joskus huonon ennusteen, jättää käyttäjille epämiellyttävän tunteen siitä, että he saattavat joutua kärsimään joka kerta, kun uusi ennuste julkaistaan (Stevenson, 2015 s. 75–76).

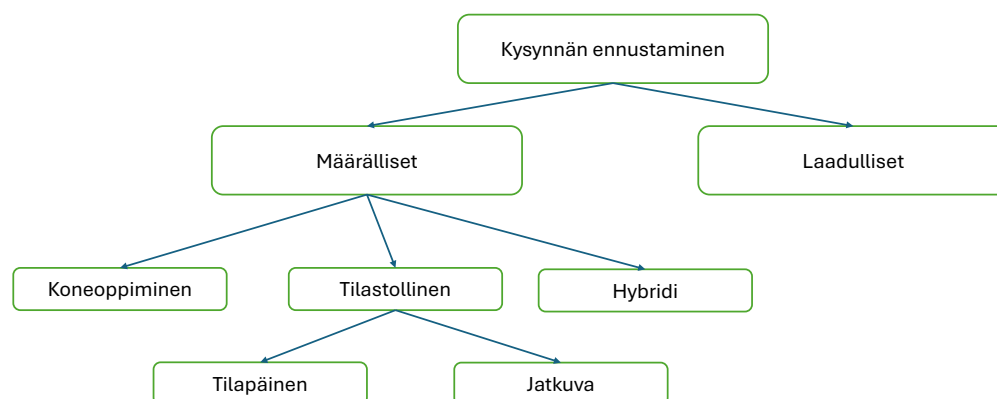
Neljäntenä ennuste olisi ilmaistava mielekkäissä yksiköissä. Työtehtävän mukaan ennusteen tulkitsejan on saatava ennusteesta oleellinen informaatio. Taloussuunnittelijoiden on tiedettävä, kuinka monta dollaria tarvitaan, tuotannonsuunnittelijoiden on tiedettävä, kuinka monta yksikköä tarvitaan ja aikataulutajien on tiedettävä, mitä koneita ja taitoja tarvitaan. Yksiköiden valinta riippuu siis käyttäjän tarpeista. Ennusteen on oltava myös kirjallinen. Vaikka tämä ei täydellisesti takaa, että kaikki asianosaiset käyttävät samoja tietoja, se ainakin lisää sen todennäköisyyttä. Lisäksi kirjallinen ennuste mahdollistaa objektiivisen perustan ennusteen arvioinnille, kun todelliset tulokset ovat saapuneet. (Stevenson, 2015 s. 75–76)

Viimeisten elementtien mukaan ennustetekniikan tulisi olla ymmärrettävissä ja käytettävissä sekä sen tulisi olla kustannustehokas. Vaikka koneoppimismenetelmät voivat olla monimutkaisia, on tärkeää, että ennusteprosessi ja sen tulokset ovat ymmärrettäviä

niille, jotka niitä käyttävät päätöksenteossa (Ahamed et al., 2023). Tämä voi tarkoittaa mallien toiminnan selittämistä tai käyttäjäystävällisten työkalujen tarjoamista ennusteiden hyödyntämiseen. Viimeisenä elementtinä kustannustehokkuudella tarkoitetaan sitä, että ennustemallin kehittämisen ja ylläpitämisen kustannusten tulisi olla suhteessa sen tuomaan hyötyyn (Stevenson, 2015 s. 75–76). Yhteenvedona voidaan todeta, että hyvä kysynnän ennuste tuotannosuunnittelussa koneoppimista hyödyntäen on tarkka, luotettava, ajantasainen, ymmärrettävä, käyttökelpoinen ja kustannustehokas. Nämä piirteet varmistavat, että ennusteet tukevat tehokkaasti liiketoiminnan tavoitteita ja mahdollistavat optimoidut tuotanto- ja resurssinhallintapäätökset.

2.4 Kysynnän ennustamisen metodit

Tavallisimmat kysynnän ennustamisessa käytetyt metodit ja mallit on esitetty kuvassa 3. Ennustamiselle on olemassa kaksi pääasiallista ennustemalliperhettä: laadulliset sekä määrälliset ennustemallit. Määrällisiin ennustemalleihin voidaan esittää kolme alakategoriaa: tilastolliset metodit, koneoppimisen metodit sekä hybridimetodit. Tuotteiden taustalla olevien kysyntämallien perusteella ennustemenetelmät voidaan jakaa myös jatkuvan kysynnän menetelmiin ja tilapäisen/jaksottaisen kysynnän menetelmiin. Jaksottavuuden kaltaisten kuvioiden tunnistaminen on tärkeää päätettäessä, mikä menetelmä – jatkuvan kysynnän vai jaksottaisen kysynnän menetelmä – on sopivin ennusteongelmaan. (Benhamida et al., 2021)



Kuva 3: Kysynnän ennustamisen metodien luokittelu (mukaillen Benhamida et al., 2021)

Laadullinen ennustaminen, eli arvioiva ennustaminen, on yleinen tekniikka, joka perustuu asiantuntija-arvioon tai kuluttajien mielipiteisiin numeerisen analyysin sijaan. Laadullinen ennustaminen on hyödyllistä ja usein tarpeellista, jos määrällisiin menetelmiin tarvittava data historiasta puuttuu. Se on myös toimiva tekniikka, jos historiallisilla arvoilla on vain vähän tai ei ollenkaan merkitystä tulevaisuuden arvoihin. Vaikka laadulliset ennustemenetelmät ovat yleinen käytäntö, voivat ne johtaa ennakkoluuloihin, koska ne riippuvat pitkälti ihmisten mielipiteistä. Ihmisten mielipiteisiin vaikuttavat usein henkilökohtaiset tai poliittiset tavoitteet. Laadullisen ennustamisen haaste on myös, että asiantuntijalla tai ennustajalla on taipumus antaa suurempi painoarvo viimeaikaisille historiallisille tapahtumille, ja näin ollen saadut ennusteet ovat lähellä vertailupistettä. (Benhamida et al., 2021)

Määrällinen ennustaminen puolestaan perustuu matemaattisiin eli tilastollisiin malleihin. Määrällisten ennustemallien ydin on ekstrapolointi, joka tarkoittaa, että ennustemalli käyttää pelkästään historiallista dataa ennustamiseen. (Abolghasemi et al., 2020) Benhamidan et al. (2021) mukaan määrällinen ennustaminen on objektiivisempää kuin laadullinen ennustaminen. Sitä suositellaankin käyttämään, kun historiallista dataa on riittävästi saatavilla ja se korreloi melko hyvin tulevaisuuden arvojen kanssa, eli jos menneisyyden mallit voivat jatkua myös tulevaisuudessa (Benhamida et al., 2021). Määrällinen ennustaminen voi käyttää joko yksittäisenä ajankohtana kerättyjä tietoja tai aikasarjadataa. Aikasarjadata on kerätty tasaisten väliajoin suoritettujen mittauksen avulla. (Benhamida et al., 2021)

Määrällisessä ennustamisessa hybridimenetelmä tarkoittaa sitä, että siinä yhdistetään koneoppimista tilastollisten menetelmien kanssa, jotta voidaan hyödyntää molempien etuja (Benhamida et al., 2021). Kun nämä yhdistetään, tulos ennusteen tarkkuudesta usein kasvaa merkittävästi. Tämä hyöty saadaan yksittäisten menetelmien luontaisesta yhteensovittamisesta. Ajatuksena on yhdistää erilaisia menetelmiä, joilla on omat erityispiirteensä, jotta yksittäisten tekniikoiden rajoituksia voidaan kompensoida ja näin parantaa ennusteen suorituskykyä. (Petropoulos et al., 2022)

2.5 Kysynnän ennustamisen mittaaminen

Kysynnän ennustamisen suoriutumista mitataan KPI:lla (Key Performance Indicators), joita ovat esimerkiksi tarkkuus, poikkeama ja virhemittaukset. KPI:t tarjoavat mahdollisuuden mitata kysynnän ennustamisen onnistumista ja tunnistaa kehitettävät alueet. (Tadayonrad & Ndiaye, 2023) Tavallisia tarkkuuden mittareita ja näiden laskukaavoja ovat esimerkiksi Mean Absolute Error

$$(\text{MAE}) = \frac{1}{n} \sum_{t=1}^n |y_t - f_t|, \quad (1)$$

Mean Absolute Percentage Error

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - f_t}{y_t} \right| \quad (2)$$

ja Root Mean Squared Error

$$(\text{RMSE}) = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - f_t)^2}, \quad (3)$$

joissa y_t tarkoittaa toteumaa ja f_t tarkoittaa ennustetta ajalle t (Wahedi et al., 2023).

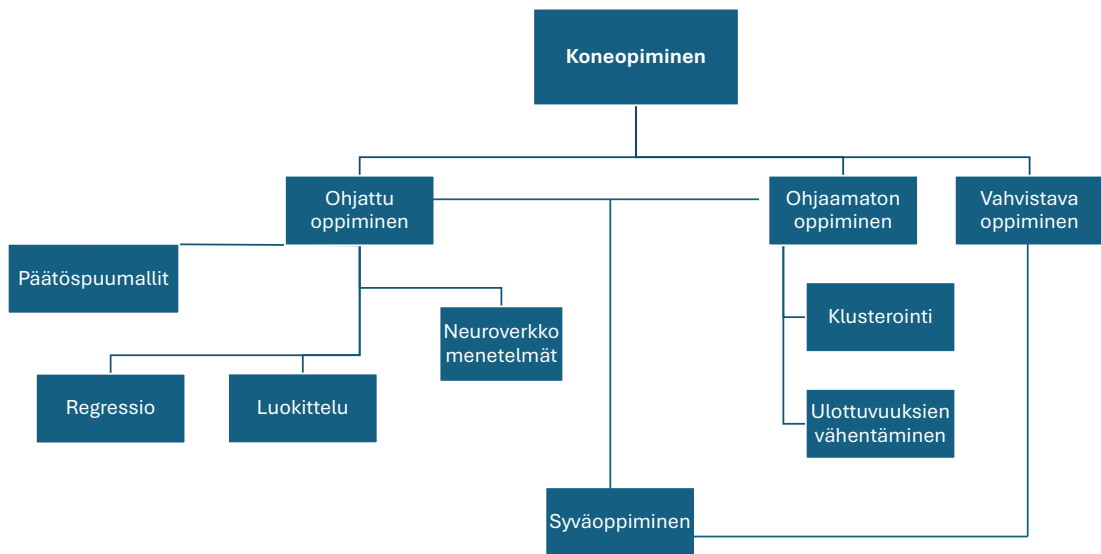
Edellä mainitut kaavat ovat tavallisia, kun arvioidaan kysynnän ennustamisen kokonais-suoritusta. Nämä mittaukset vertaavat ennustettua kysyntää toteutuneeseen kysyntään, ja mitä pienempi virhe saadaan, sitä parempi käytetty ennustuksen malli on. (Tadayonrad & Ndiaye, 2023) Wahedin et al. (2023) mukaan on kuitenkin huomattu, että nämä suorituskykymittarit eivät aina kerro yrityksen haluamaa informaatiota heidän näkökulmastaan. Sen vuoksi ennustetarkkuuden arvioinnissa käytetään myös seuraavia keskeisiä suorituskykyindikaattoreita: täyttöaste sekä keskimääräinen varastotaso ja kokonaispito-kustannus. Täyttöaste kertoo prosenttiosuuden kysynnästä, joka voidaan täyttää va-raston kapasiteetilla tietynä ajankohtana. Keskimääräinen varastotaso ja kokonaispito-kustannus kertovat kunkin jakson yhteenlasketut hallussapitokustannukset sekä va-rastohävikit, mikä puolestaan kertoo kuinka monta kertaa todellinen kysyntä ylittää va-rastotason. Luetellut keskeiset suorituskykyindikaattorit on valittu tarkoituksella sekä akatee-misten että teollisten vaikutusten perusteella, koska tavoitteena on mitata suorituskykyä matemaattisesta ja käytännöllisestä näkökulmasta. (Wahedi et al., 2023)

3. TEKOÄLYN ROOLI KYSYNNÄN ENNUSTAMISSESSA

Tässä luvussa käsitellään koneoppimista kirjallisuuden perusteella. Ensimmäisessä alaluvussa kerrotaan koneoppimisen määritelmä ja esitetään metodit, joihin koneoppiminen voidaan jakaa. Toisessa alaluvussa esitetään haasteita sekä riskejä, joita liittyy koneoppimisen käyttöön kysynnän ennustamisessa.

3.1 Koneoppiminen

Tekoälyn laajaan sateenvarjioon kuuluu erilaisia sovelluksia ja tekniikoita, jotka vaihtelevat hermoverkoista puheen ja kuvioden tunnistamiseen, geneettisiin algoritmeihin ja syvään oppimiseen. Koneoppiminen tarkoittaa algoritmeja, jotka mahdollistavat järjestelmän itsenäisen oppimisen datasta ilman eksplisiittisiä ohjeita. (Jarrahi, 2018) Rožanec (2021) mukaan koneoppimisen oppimisalgoritmit voivat ennakoida ihmistä paremmin esimerkiksi tulevaisuuden myyntiä oppimalla monimutkaisia malleja sekä trendejä datasta. Hyvän ennusteen tekeminen on mahdollista analysoimalla mahdollisimman laajoja datakokonaisuuksia ja paljastamalla sieltä piilossa olevia malleja. Koneoppimisen algoritmit voivat testata itseään reaaliaikaista dataa käyttämällä varmistaakseen, että asiakkaiden käyttäytyminen muuttuu, ja optimoida algoritmin sen mukaan parhaan tarkkuuden saavuttamiseksi. Koneoppimisen kouluttamisessa erittäin suuret määrät dataa auttavat sitä oppimaan piilotettuja malleja ja tarjoamaan tarkempia ennusteita. (Rožanec, 2021) Koneoppimisen järjestelmät on rakennettu seulomaan läpi suuria datamääriä, joten niiden soveltaminen tuotantoympäristöissä mahdollistaa sellaisen lisädatan keräämisen, jota voidaan hyödyntää tulevien päätösten ohjaamisessa (Ahamed et al., 2023). Koneoppiminen ja sen jako alakategorioihin on esitetty kuvassa 4.



Kuva 4: Koneoppimisen luokittelu alakategorioihin (Jordan & Mitchell, 2015; Ahamed et al., 2023)

Lisäksi oleellista koneoppimisen algoritmeissa on, että ne ovat kykeneviä parantamaan kysynnän ennustamisen tarkkuutta tunnistamalla yhteyksiä ulkoisten muuttujien kuten kausivaihtelun, talouden, kulttuurillisten ilmiöiden tai kuluttajien ostotrendien välillä. Tämä puolestaan antaa valmistajille mahdollisuuden kustomoida tuotantoaan ja markkinointiaan synkronoidakseen varastot siten, että oikeita tuotteita on saatavilla oikea määrä oikeaan aikaan. (Vaid et al., 2023) Ahamedin et al. (2023) mukaan ennustamisessa käytetään useita koneoppimisen menetelmiä, kuten aikasarjaennustamista, regressioanalyysiä sekä luokittelumalleja. Nämä mallit analysoivat historiallista dataa tunnistakseen trendejä ja malleja tulevien tulosten ennustamiseksi. Niistä kaikki pohjautuvat joko ohjattuun oppimiseen, ohjaamattomaan oppimiseen tai vahvistavaan oppimiseen, jotka ovat esitetty kuvassa 4 ja selitetty taulukossa 2. Useiden eri menetelmien vuoksi eri liiketoiminnan tarpeet ja datan ominaisuudet voivat suosia erilaisia koneoppimisalgoritmeja. (Ahamed et al., 2023)

Taulukko 2: Koneoppimisen tärkeimmät menetit

Metodi	Selite
Ohjattu oppiminen	Keskittyy funktion approksimointiin annetun syöte–tulosparien joukon perusteella. Algoritmia koulutetaan datalla, jossa syötteet ja niihin liittyvät oikeat vastaukset (tulokset) ovat tiedossa. Tämän perusteella algoritmi oppii muodostamaan yhteyden syötteiden ja tulosten välillä ja voi myöhemmin ennustaa tuloksia uusille, näkemättömille syötteille. (Oluyisola et al., 2022)
Ohjaamaton oppiminen	Tietystä tietokokonaisuudesta x datan tutkimista ja piilotettujen rakenteiden sekä mallien löytämistä ilman valmiita luokittelutietoja. (Usuga Cadadavid et al., 2020)
Vahvistava oppiminen	Mahdollistaa sellaisten toimien oppimisen, joita tietyn ympäristön kanssa vuorovaikutuksessa olevan tekoälyagentin on suoritettava. Esimerkiksi varastossa olevan automaattisen ajoneuvon opettaminen välttämään esteitä. (Usuga Cadadavid et al., 2020)

3.2 Haasteet ja riskit

Tekoälyyn liittyvien järjestelmien käyttöönotto on todella haasteellista. Se vaatii merkittävää alkuinvestointia, oikeanlaista tietoinfrastruktuuria sekä ammattitaitoista henkilökuntaa organisaatiossa. Lisäksi tekoälypohjaisen ennustamisen tarkkuus riippuu syöttötietojen laadusta ja relevanttiudesta. (Doanh et al., 2023) Erityisesti koneoppimismalleille datan laatu on kriittistä, sillä ne tarvitsevat sitä todella paljon ja jos data on yhtään väärinryhmittä, ennusteet ovat todennäköisesti epäluotettavia (Malviya & Bhandari, 2024).

Tekoälypohjaiseen kysynnän ennustamiseen liittyy myös muita huomioon otettavia asioita. Eettiset näkökulmat, tietosuojahuolet ja tarve läpinäkyvään päätöksentekoprosessiin säilyvät tärkeinä pointteina integroitaessa tekoälyä kysynnän ennustamisen toimintoihin. (Doanh et al., 2023; Jordan & Mitchell, 2015) Irshadullahin et al. (2025) mukaan myös mahdolliset tietomurrot, kyberuhkat ja muut säännösten seuraamiset nousevat haasteeksi tekoälyn integroinnissa osaksi toimitusketjua. Näiden haasteiden ymmärtäminen ja tekoälyn käyttöönoton parhaiden käytäntöjen tunnistaminen on ratkaisevan tärkeää yrityksille, jotka pyrkivät saavuttamaan kilpailuetua tällä alueella. (Irshadullah et al., 2025)

Vaikka tekoälyjärjestelmät tukevat analyttistä päätöksentekotapaa, ovat ne vähemmän kykeneviä ymmärtämään maalaisjärkeä vaativia tilanteita kuin ihmiset. Lisäksi ihmisiin verrattuna ne ovat vähemmän elinkelpoisia epävarmoissa tai arvaamattomissa ympäristöissä – erityisesti ennalta määritellyn tietoalueen ulkopuolella. (Jarrahi, 2018) Niitä siis puuttuu intuitiivisuus, jota oikeat ihmiset hyödyntävät päätöksenteossa, eikä tämä osaaaminen tule katoamaan ihmisiltä. Malviya ja Bhandari (2024) tunnistavat tutkimusaukkoja muun muassa koneoppimisen muodostamien mallien tulkittavuudessa, reaaliaikaisessa validoinnissa sekä integraatiossa olemassa oleviin järjestelmiin. Ihmisille siis koneoppimisen mallien monimutkaisuus on haaste, sillä niitä voi olla vaikea ymmärtää, mikä voi hankaloittaa puolestaan tulosten tulkintaa ja niihin perustuvien päätösten tekemistä. Haasteiden lisäksi yritysten on varmistettava, että heidän koneoppimismallejaan päivitetään ja kehitetään säännöllisesti, jotta ne pysyvät ajan tasalla muun muassa asiakaskäyttäytymisen ja markkinatrendien muutoksissa. (Malviya & Bhandari, 2024)

4. TEKOÄLYN KÄYTÄNNÖN HYÖDYT KYSYNNÄN ENNUSTAMISEN TYÖKALUNA

Tässä luvussa käsitellään kirjallisuuskatsauksen tuloksia taulukon 1 mukaiseen tutkimusaineistoon perustuen. Tutkimusaineistoa käsiteltäessä huomioidaan luvussa 1.2 esitetyt tutkimuskysymykset. Näistä ensimmäinen tarkastelee koneoppimisen hyödyntämisen keinoja kysynnän ennustamisessa. Tätä kysymystä käsitellään erikseen määrällisestä sekä laadullisesta näkökulmasta *kuvan 2* mukaisesti. Toinen tutkimuskysymyksistä käsittelee tekoälypohjaisen kysynnän ennustamisen vaikutusta yrityksen toimintaan ja sen resurssien käyttöön.

4.1 Tekoälyn soveltuvuus määrällisessä ennustamisessa

Määrällinen ennustaminen on olennainen osa liiketoiminnan suunnittelua ja päätöksentekoa. Se hyödyntää historiallista dataa ja tilastollisia menetelmiä tulevien trendien ja kysynnän arvioimiseen. Viime vuosina erityisesti koneoppimisen kehitys on avannut uusia mahdollisuuksia määrällisen ennustamisen tehostamiseen ja tarkkuuden parantamiseen. Määrällisessä ennustamisessa datasta oppiminen tarkoittaa historiallisten myynti-, varasto- tai muiden relevanttien tietojen analysointia kaavojen ja trendien tunnistamiseksi. (Ahamed et al., 2023)

Kysynnän ennustamisesta koneoppimisen algoritmeja hyödyntäen on tehty paljon tutkimuksia. Taulukossa 3 esitetään näistä muutamia eri algoritmeja käytettäviä. Kyseisissä tutkimuksissa konteksti on samantyyppinen, joten voidaan havainnollistaa eri metodien ominaisuuksia. Falatouri et al. (2022) tutkivat kysynnän ennustamista vähittäiskaupan toimitusketjussa hyödyntäen aikasarja-algoritmeja. Tutkimuksessa käytetty aineisto koostui 37 kuukauden myyntitiedoista itävaltalaiselta vähittäismyyjältä. Tutkimuksessa tunnistettiin suurimmaksi ongelmaksi se, että tuotteiden kysynnän laskeminen yksittäisten myymälöiden tasolla vaatii paljon työtä. Tämän ongelman ratkaisemiseksi ehdotetaan koneoppimismenetelmien käyttöä hybridianalyysien pohjana, jotta ennustamista voidaan syventää yksittäisten myymälöiden tasolla. Esimerkiksi myymälöiden ryhmittely myyntikäyttäytymisen perusteella ja mallien kouluttaminen erikseen kullekin ryhmälle voisi parantaa ennustemallien laatua. (Falatouri et al., 2022)

Taulukko 3: Kysynnän ennustamisen tutkimuksia

Kirjallisuuslähde	Tavoite	Metodi	Konteksti
Falaturi et al., 2022	Kysynnän ennustaminen toimitusketju-tasolla	Aikasarja	Jälleenmyynti (elin-tarvikkeet)
Abbasimehr et al., 2020	Kysynnän ennustaminen toimitusketju-tasolla	Neuroverkosto	Jälleenmyynti (huonekalut)
Qu et al., 2017	Kysynnän ennustaminen ja hinnan optimointi	Päätöspuumalli	Jälleenmyynti (puoliluksus sektori)

Abbasimehr et al. (2020) esittivät optimaalisen kysynnän ennustemallin, joka perustui LSTM- verkkoon (Long Short –Term Memory) eli lukeutuu neuroverkostomenetelmäksi. Heidän ehdottamaa menetelmää verrattiin esimerkiksi tilastollisiin aikasarjamenetelmiin. Arviointimittareina tutkimuksessa käytettiin *kaavaa 3*. Tulokset osoittivat, että heidän artikkelissaan esitetty algoritmi saavutti parhaan sijoituksen arviointimittareiden perusteella. Tutkimuksen mukaan se indikoi, että tekoälypohjaisilla menetelmillä on erinomainen kyky tunnistaa kaavoja datasta. (Abbasimehr et al., 2020) Qu et al. (2017) puolestaan pyrkivät tutkimuksessaan ennustamaan kysyntää puoliluksussupermarket -sektorilla hintojen optimointia varten. He kehittivät päätöspuumallin ja käyttivät mallin kouluttamiseen 2,5 vuoden myyntidataa useista myymälöistä 45 eri alueelta. Tutkimuksessa käytettiin mittarina *kaavaa 2*. Tutkimuksen mukaan päätöspuumalli tuotti pienimmän virheen käytetyistä algoritmeista. (Qu et al., 2017) Taulukossa 3 esitetyistä tutkimuksista voidaan huomata, että vaikka konteksti olisi samantyylinen, tulee tilanteeseen nähden aina valita oma ennustamisen malli.

Tadayonrad & Ndiaye (2023) toteavat Aamerin et al. (2020) tutkimuksesta, että taulukossa 4 esitettävät algoritmit: neuroverkostot, regressio sekä aikasarja, ovat parhaita tekoälypohjaisia kysynnän ennustamisen algoritmeja. Nämä algoritmit pohjautuvat *kuvaan 3*. Taulukossa 4 on selitetty kyseisille algoritmeille niiden keskeiset hyödyt ja heikoudet liittyen kysynnän ennustamiseen, jotka vaikuttavat niiden soveltuvuuteen eri tilanteissa. Tämä vertailu korostaa tarvetta valita ennustemenetelmä tapauskohtaisesti sen mukaan, millaisia piirteitä ennustettava ilmiö sisältää.

Taulukko 4: Kysynnän ennustamisen menetelmien hyötyjen ja heikkouksien vertailu (Tadayonrad & Ndiaye, 2023)

	Neuroverkostot	Regressio	Aikasarja
Hyödyt	Pystyy määrittelemään epälineaariset suhteet riippuvien ja riippumattomien muuttujien välillä sekä havaita todennäköiset riippumattomien muuttujien väliset korrelaatiot	Soveltuu suurille tietomäärille lineaarista ja epälineaarista dataa käyttäen mallin rakentamiseen	Parempi aikamallien ymmärtäminen ja tunnistaminen
Heikkoudet	Taipumus liialliseen sovittamiseen, juuttuminen paikalliseen optimiin	Tulokset, jotka liittyvät seuraavien tekijöiden määrittämiseen parametreihin ja absoluuttiseen optimittomuuteen	Epälineaaristen mallien rakentamisen epäonnistuminen

Taulukossa 5 on koottu kirjallisuuslähteitä, joissa on hyödynnetty tekoälymalleja kysynnän ennustamiseen. Taulukossa on jaoteltu käytetyt tekoälyn osa-alueet kuvan 2 ja 3 luokitteluiden mukaisesti. Lisäksi siinä on esitetty, mihin ennustemenetelmään tekoälyratkaisun suorituskykyä on tutkimuksessa verrattu. Taulukon lopputulosarake kuvaa, miten tekoälypohjainen ratkaisu on suoriutunut suhteessa verrokkimenetelmään kyseisen kirjallisuuslähteen mukaan.

Taulukko 5: Määrällisten ennustemenetelmien vertailu

Kirjallisuuslähde	Metodi	Mihin verrattu	Lopputulos
Vallés-Pérez et al. (2022)	Syväoppiminen	Tilastollinen menetelmä	Parempi ennustetarkkuus, alin teoreettinen laskennallinen kustannus
Petropoulos et al. (2022)	Hybridimenetelmä	Neuroverkkomenetelmä	Parempi suoritus
Smyl (2020)	Hybridimenetelmä	M4- ennustekilpailu	Paras suorituskyky
Abolghasemi et al. (2020)	Tilastollinen	Koneoppiminen	Tilastollinen malli suoriutui paremmin kuin koneoppimismenetelmät
Benhamida et al. (2021)	Hybridimenetelmät	Tilastolliset menetelmät	Hybridimenetelmät olivat tarkempia
Makridakis et al. (2018a)	Ohjattu oppiminen, ohjaamaton oppiminen	Tilastolliset menetelmät, M3-ennustekilpailu	Tilastolliset mallit suoriutuivat paremmin, koneoppimismenetelmällä suurempi laskentakustannus
Makridakis et al. (2018b)	Hybridimenetelmä	Tilastolliset menetelmät	Hybridimenetelmällä tarkimmat tulokset

Smyl (2020) esittelee hybridiennustusmenetelmän, joka yhdistää perinteisen eksponentiaalisen tasoituksen mallin kehittyneisiin pitkäkestoisiin muistiin perustuviin neuroverkkoihin yhteisessä viitekehyksessä. Tämän hybridimenetelmän tuloksena syntyi ennustusmenetelmä, joka saavutti parhaan suorituskyvyn M4-ennustuskilpailussa. (Smyl 2020)

Vaikka suurin osa kirjallisuudesta toteaa koneoppimisen olevan hyödyllinen ennusteiden parantamisessa, löytyy siitä myös ristiriitaisia todisteita. Abolghasemi et al. (2020) toteavat tutkimuksessaan, että kehittämänsä tilastollinen menetelmä suoriutui paremmin ennustetarkkuuden kannalta sekä huonojen ennusteiden syntyemisessä. Huonot ennusteet tässä tapauksessa johtuivat kysyntätilojen muutoksesta. Tutkimuksessa korostetaan myös, että kyseinen malli mahdollistaa asiantuntijoiden harkinnan objektiivisen sisällyttämisen ennustusprosessiin, mikä nähdään positiivisena hyötynä. (Abolghasemi et al., 2020). Myös Makridakis et al. (2018) vertasivat kymmentä kuuluisinta koneoppimisen metodia kahdeksaan tilastolliseen menetelmään ja niiden tuloksiin. Tutkimuksessa käytettiin muun muassa *kaavaa 2* tarkkuuden arvioinnissa. Tuloksena tilastolliset menetelmät suoriutuivat paremmin kuin kaikki koneoppimismenetelmät sekä käytettyjen tarkkuusmittareiden että kaikkien ennustejaksojen osalta. Tutkijat toteavat myös koneoppimisen haasteeksi sen laskentatehontarpeen, joka on huomattavasti suurempi kuin tilastollisten menetelmien. (Makridakis et al., 2018) Kirjallisuuden perusteella syväoppimismenetelmien etuina puolestaan pidettiin vähäistä tarvetta syötedatan esikäsittelylle sekä mallien hyvää skaalautuvuutta, mikä mahdollistaa ennusteiden tuottamisen erilaisiin kysyntämalleihin ja eri aikaväleille saman tekoälymallin avulla (Vallés-Pérez et al., 2022).

Hybridimenetelmän suoritus ennustamisessa riippuu puolestaan metodeista, jotka siihen valitaan. Nämä metodit tulisi valita erityisesti aina kyseistä ongelmaa varten ja asettaa niille oikeat parametrit. Tällaisten hybridimenetelmien etuna on niiden luotettavuus äkillisiä muutoksia vastaan keskeisten parametrien arvoissa. Ne kuitenkin vaativat lisätietämystä ja ymmärrystä perusmenetelmistä ja niiden haittapuolena on hidas reagointiaika uuteen dataan. Koska nämä hybridimenetelmät ottavat huomioon mallin jäännösvirheet, niiden tavoitteena on parantaa perusmenetelmien ennusteita soveltamalla korjauksia ennusteisiin. Näiden hybridimenetelmien haittapuolena on kuitenkin lisääntynyt laskentaaika, sillä myös jäännösvirheet on arvioitava. Lisäksi tällaiset hybridimenetelmät eivät ole yleistettävissä, vaan ne riippuvat sovelluskohteesta. Monissa tapauksissa hybridimenetelmät suoriutuvat paremmin kuin muut (yksittäiset) menetelmät. (Petropoulos et al., 2022)

Tulokset osoittavat, että eri menetelmillä on erilaisia vahvuuksia riippuen sovelluskohteesta ja vertailuasetelmasta. Esimerkiksi hybridimenetelmät ovat usein osoittautuneet tehokkaimmiksi ennustetarkkuuden näkökulmasta, kun taas tilastolliset menetelmät voivat yhä olla kilpailukykyisiä ja kevyempiä laskennallisesti verrattuna nykyaikaisiin koneoppimiskäytäntöihin. Taulukko 5 tarjoaa siis tiiviin katsauksen määrällisten ennustemenetelmien vertailuun ja niihin liittyviin keskeisiin havaintoihin kirjallisuudessa.

4.2 Tekoälyn soveltuvuus laadullisessa ennustamisessa

Lähdekirjallisuuden perusteella on havaittavissa selkeä ero tekoälyn käytössä määrällisen ja laadullisen ennustamisen välillä. Tekoälyä hyödynnetään selvästi yleisemmin määrällisessä ennustamisessa, kun taas sen käyttö laadullisten ennusteiden tukena on toistaiseksi harvinaisempaa. Joissain tapauksissa koneoppimismenetelmiä voidaan kuitenkin soveltaa myös laadulliseen ennustamiseen, erityisesti tilanteissa, joissa perinteisestikin hyödynnettäisiin asiantuntija-arvioita tai kontekstuaalista tietoa. Koneoppiminen voi tarjota merkittävää lisäarvoa myös laadullisessa ennustamisessa erityisesti silloin, kun se toimii asiantuntijoiden päätöksenteon tukena ja auttaa käsittelemään monimutkaista tai kontekstisidonnaista tietoa (Petropoulos et al., 2022).

Stekler & Symington (2016) osoittavat tutkimuksessaan, joka keskittyy Yhdysvaltain keskuspankin (FOMC) kokouspöytäkirjoihin, että laadullisia arvioita voidaan muuttaa kvantitatiiviseksi indeksiksi ennusteita varten. Vaikka tutkimus ei suoraan liity teolliseen alaan, voidaan tätä pitää vastaavana esimerkkinä teollisuudessa sovellettavaksi. Tutkimuksessa kehitettävä määrällinen indeksi auttaa ymmärtämään, miten FOMC:n jäsenet arvioivat talouden tilaa ja tulevaisuuden näkymiä. Tekoäly voi hyödyntää vastaavia menetelmiä analysoidakseen suuria määriä tekstipohjaista dataa tunnistaa keskeiset teemat ja muuttaakseen laadulliset arviot määrällisiksi mittareiksi. Tämä mahdollistaa tarkemmat ja monipuolisemmat ennusteet, jotka voivat muun muassa parantaa päätöksenteon prosessia. (Stekler & Symington, 2016)

Laadullisia analyysimenetelmiä ovat esimerkiksi Delphi- ja markkinatutkimukset, joissa kerätään asiantuntijoilta ja muilta sidosryhmiltä tietoa ennusteiden tekemiseksi tulevasta kysynnästä. Nämä menetelmät voivat olla hyödyllisiä, kun halutaan ymmärtää kysyntään vaikuttavia subjektiivisia tekijöitä, kuten kuluttajien mieltymyksiä ja markkinatrendejä. Koneoppimisen menetelmiä on viime vuosina hyödynnetty myös laadullisten menetelmien tukena, esimerkiksi datan käsittelyssä, ja sen on todettu olevan tarkempaa ja tehokkaampaa kuin pelkästään perinteiset menetelmät ilman tekoälyä. (Tadayonrad & Ndiaye, 2023)

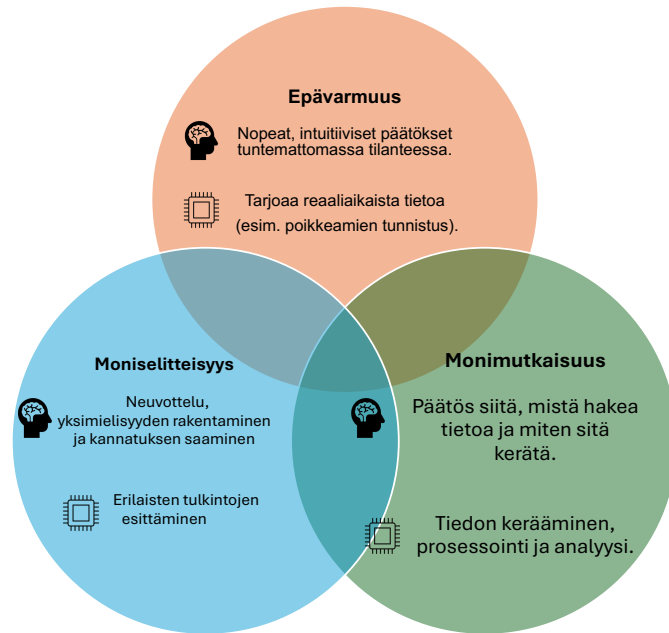
Laadulliseen ennustamiseen liittyy myös käytännön haasteita. Kun koneoppimista hyödynnetään laadullisen ennustamisen tukena, on asiantuntijoilla edelleen mahdollisuus tehdä ennusteiden säätöjä. Näitä säätöjä tehdään harvoin systemaattisesti, joten asiantuntijat soveltavat tietämystään usein ilman selkeää rakennetta tai tukea. (Abolghasemi et al., 2020) Tämä voi johtaa heikompaan ennustetarkkuuteen verrattuna rakenteellisesti ohjattuun lähestymistapaan. Abolghasemi et al. (2020) ovat kuitenkin todenneet yhden mahdollisen ratkaisun tähän haasteeseen. Artikkelin mukaan ihanteellisessa tilanteessa

voitaisiin hyödyntää ennustetukijärjestelmää, joka tarjoaa perusennusteen avulla sekä rakenteellisen tuen että palautteen asiantuntijalle. Tällainen järjestelmä keventää asiantuntijan kognitiivista kuormitusta ja voi parantaa ennusteen tarkkuutta. (Abolghasemi et al., 2020) Uudet koneoppimismenetelmät, jotka kykenevät yhteistyöhön ihmisten kanssa monimutkaisten tietoaaineistojen analysoimisessa, voisivat yhdistää koneiden kyvyn havaita hienovaraisia tilastollisia säännönmukaisuuksia valtavista datamassoista ja ihmisten kyvyn hyödyntää taustatietoa, luoda uskottavia selityksiä ja ehdottaa uusia hypoteeseja (Jordan & Mitchell 2015).

4.3 Tekoälyn ja ihmisen yhteistyö päätöksenteossa epävarmuuden vallitessa

Tekoäly voi merkittävästi tukea yritysten päätöksentekoa erityisesti epävarmuuden vallitessa. Epävarmuus syntyy tiedon puutteesta, joka vaikeuttaa tilanteiden tulkintaa ja päätösten tekemistä. (Jarrahi 2018) Tämä voi johtua niin sisäisistä kuin ulkoisista tekijöistä, kuten resurssipulasta, uusista kilpailijoista tai teknologian murroksesta. Tekoäly ja ennakkoiva analytiikka auttavat päätöksentekijöitä tunnistamaan trendejä ja yhteyksiä monimutkaisista tietoaaineistoista sekä tarjoamaan reaaliaikaisia varoitusmerkkejä mahdollisista ongelmista. (Guszcza et al., Jarrahi 2018 mukaan) Esimerkiksi konsultointiyritykset, kuten Deloitte ja McKinsey, ovat kehittäneet tekoälytyökaluja, jotka valvovat organisaatioiden toimintaympäristöä ja auttavat strategisessa suunnittelussa. Nämä työkalut voivat auttaa johtajia havaitsemaan poikkeamia tarjoamalla reaaliaikaista tietoa varhaisista varoitusmerkeistä, jotka kertovat suuremmista ongelmista ja mahdollistavat oikea-aikaiset korjaavat toimet. (Jarrahi 2018)

Vaikka tekoäly voi käsitellä valtavia tietomääriä ja tehdä tarkkoja ennusteita, se ei kykene korvaamaan ihmisten intuitiivista päätöksentekoa erityisesti tilanteissa, joissa on vähän vertailukohtia aiemmista päätöksistä. Ihmisen intuitio perustuu usein kokemukseen ja hiljaiseen tietoon, jota on vaikea mallintaa algoritmeilla (Sadler-Smith & Shefy, 2004). Tämä näkyy esimerkiksi strategisessa suunnittelussa ja tuotekehityksessä, joissa luovuus ja kokonaisvaltainen ajattelu ovat keskeisiä (Jarrahi 2018). Tässä yhteydessä inhimilliset päätöksentekijät käyttävät usein intuitiivista lähestymistapaa, jossa hyödynnetään vuosien hiljaiseen kokemukseen ja henkilökohtaiseen arvostelukykyyn perustuvaa näkemystä ja laadullista arviointia. Näiden päätösten taustalla olevia syitä on hyvin vaikea ilmaista sen lisäksi, että ne vain tuntuvat oikeilta. (Sadler-Smith & Shefy, 2004)



Kuva 5: Ihmisten ja tekoälyn täydentävyys päätöksentekotilanteissa (Mukaien Jarrahi, 2018)

Kuva 5 havainnollistaa ihmisen ja tekoälyn täydentävyyttä päätöksentekotilanteissa, joille tyypillisiä piirteitä ovat epävarmuus, monimutkaisuus ja moniselitteisyys. Kuvasta 5 huomataan, kuinka ihmisten ja tekoälyn kumppanuus toteutuu molempien vahvuuksia hyödyntäen. Ihmiset ja tekoälyteknologiat voivat tehdä yhteistyötä päätöksenteon eri osa-alueilla. Tällöin tekoäly soveltuu paremmin monimutkaisuuden hallintaan analyttisten lähestymistapojen avulla, kun taas ihmiset voivat keskittyä epävarmuuteen ja moniselitteisyyteen luovilla ja intuitiivisilla lähestymistavoilla. Silti myös monimutkaisuudessa ihmisellä on intuitiivisia keinoja ohjata tekoälyä ja käyttää sitä parhaalla mahdollisella tavalla. (Jarrahi, 2018) Ihmisen arvo ennustamisessa perustuu juuri siihen, että asiantuntijat hallitsevat tuotekohtaisen tietämyksen ja kokemuksen, jota tilastomallit eivät pysty mallintamaan (Abolghasemi et al., 2020). Jarrahin (2018) mukaan monimutkaisimmat päätökset – joissa tekoälyllä on kuitenkin etulyöntiasema – vaativat todennäköisesti epävarmuuden ja moniselitteisyyden elementtejä, mikä edellyttää myös ihmisen osallistumista. Näin ollen ihmiset ja tekoäly toimivat yhdessä lähes kaikessa monimutkaisessa päätöksenteossa. (Jarrahi, 2018)

5. PÄÄTELMÄT

Tässä luvussa kootaan yhteen kaikki työn kannalta keskeisimmät havainnot teoriaosiosta sekä tulososiosta. Tutkimustulosten perusteella vastataan kirjallisuuskatsauksen johdannossa esitettyihin kahteen tutkimuskysymykseen. Luvun lopussa arvioidaan myös, toteutuuko työn johdannossa esitetty tavoite. Työn tavoite oli lisätä ymmärrystä siitä, kuinka tekoälyä pystytään hyödyntämään kysynnän ennustamisessa verrattuna perinteiseen ennustamiseen.

Lähdekirjallisuuden mukaan koneoppimisen laajamittainen hyödyntäminen kysynnän ennustamisessa tarjoaa merkittäviä mahdollisuuksia, mutta samalla siitä tunnistetaan huomattavia haasteita. On selvää, että tekoälyllä ja erityisesti koneoppimisella on potentiaalia korvata perinteiset ennustamismenetelmät. Koneoppimisalgoritmit mahdollistavat järjestelmän itsenäisen oppimisen datasta ilman eksplisiittisiä ohjeita. Ne pystyvät seuloamaan läpi suuria datamääriä ja tunnistamaan piilossa olevia monimutkaisia malleja sekä trendejä, mikä voi auttaa ennustamaan kysyntää tarkemmin (Petropoulos et al., 2022). Koneoppiminen voi parantaa ennusteiden tarkkuutta erityisesti tunnistamalla yhteyksiä ulkoisten muuttujien, kuten kausivaihtelun, talouden ja kuluttajien ostotrendien välillä.

Ensimmäinen työn tutkimuskysymys käsittelee koneoppimisen hyödyntämisen keinoja kysynnän ennustamisessa. Työssä käsitellyn kirjallisuuden perusteella koneoppimista hyödynnetään erityisesti määrällisessä ennustamisessa. Määrällisessä ennustamisessa koneoppimismenetelmiä, kuten aikasarjaennustamista, regressioanalyysiä ja luokittelumalleja, käytetään historiallisen datan analysointiin ja siitä trendien sekä mallien tunnistamiseen tulosten ennustamiseksi. (Ahamed et al., 2023) Tutkimukset osoittavat, että erilaiset algoritmit, kuten neuroverkostot ja päätöspuumallit, ovat tehokkaita kysynnän ennustamisessa eri konteksteissa. (Abbasimehr et al., 2020; Qu et al., 2017)

Kirjallisuuden perusteella havaittiin, että hybridimenetelmät, joissa yhdistellään koneoppimisen algoritmeja tilastollisiin menetelmiin, ovat usein tarkimpia. Hybridimenetelmien ajatuksena on yhdistää eri menetelmien vahvuuksia ja kompensoida yksittäisten teknikoiden rajoituksia (Petropoulos et al., 2022). Esimerkiksi taulukossa 5 esitetty Smylin (2020) esittelemä hybridimenetelmä saavutti parhaan suorituskyvyn M4- ennustekilpailussa. Kyseisessä menetelmässä yhdistettiin tilastollisia menetelmiä neuroverkoston kanssa. Myös muut lähteet tukevat hybridimenetelmien tehokkuutta (Makridakis et al., 2018; Petropoulos et al., 2022; Benhamida et al., 2021).

Vaikka koneoppimisen hyödyntäminen on lähdekirjallisuuden perusteella yleisempää määrällisessä ennustamisessa, sitä voidaan soveltaa myös laadullisen ennustamisen tukena. Koneoppimismenetelmät voivat auttaa käsittelemään monimutkaista tai kontekstidonnaista tietoa ja toimia asiantuntijoiden päätöksenteon tukena. Tekoäly pystyy esimerkiksi analysoimaan suuria määriä tekstipohjaista dataa, tunnistaa keskeisiä teemoja ja muuttaa laadulliset arviot määrällisiksi mittareiksi, mikä mahdollistaa tarkemmat ja monipuolisemmat ennusteet (Tadayonrad & Ndiaye, 2023).

Toinen johdannossa esitelty tutkimuskysymys käsittelee tekoälypohjaisen kysynnän ennustamisen vaikutuksia yrityksen toimintaan ja sen resurssien käyttöön. Tarkka kysynnän ennustaminen on keskeinen osa nykyaikaista toimitusketjun hallintaa ja sillä on merkittävä rooli esimerkiksi päätöksenteossa. Tekoälypohjainen kysynnän ennustaminen voi parantaa yrityksen toimintaa merkittävästi useilla tavoilla. Tarkemmat ennusteet voivat esimerkiksi auttaa optimoimaan tuotantoprosesseja, hallitsemaan varastotasojen tehokkaasti tai vastaamaan asiakkaiden tarpeisiin nopeasti. (Doanh et al., 2023) Ne voivat myös minimoida riskejä ja parantaa päätöksenteon prosessia. Tarkemmat ennusteet auttavat myös välttämään ongelmia, jotka liittyvät liian suuriin tai pieniin varastoihin, keskeneräisiin tilauksiin, asiakkaiden tyytymättömyyteen tai varastojen loppumiseen. Koneoppimisen avulla voidaan esimerkiksi optimoida turvavarastojen tasojen hyödyntämällä suuria määriä dataa ja muita muuttujia, kuten menneitä myyntejä (Tadayonrad & Ndiaye, 2023).

Yleisesti koneoppimisen käyttöönotto kysynnän ennustamisessa tuo lähdekirjallisuuden mukaan kuitenkin mukanaan myös haasteita ja vaikutuksia resurssien käyttöön. Se vaatii merkittävää alkuinvestointia, oikeanlaista tietoinfrastruktuuria sekä ammattitaitoista henkilökuntaa. Tekoälypohjaisen ennustamisen tarkkuus riippuu vahvasti syöttötietojen laadusta ja relevanttiudesta. Vääristynyt data voi johtaa epäluotettaviin ennusteisiin. Koneoppimisen hyödyntäminen ennustamisessa verrattuna perinteisiin menetelmiin vaatii myös huomattavasti suuremman laskentatehontarpeen, johon yrityksen tulee varautua.

Lisäksi tekoälymallien tulkittavuus voi olla haasteellista ja niiden integrointi olemassa oleviin järjestelmiin vaatii paljon työtä. Mallit myös vaativat säännöllistä päivitystä asiakaskäyttäytymisen ja markkinatrendien muutosten mukaan. Eettiset näkökulmat, tietosuoja ja tarve läpinäkyvään päätöksentekoprosessiin ovat tärkeitä huomioitavia asioita.

Yhteenvetona voidaan todeta, että ennustamiseen ei ole yhtä yleispätevää parasta menetelmää, ja ennustusmenetelmien tarkkuus riippuu käytetyn datan tyypistä. Hybridimenetelmät, jotka yhdistävät sekä tilastollisia että koneoppimismenetelmiä, tuottavat tarkimmat ennustetulokset viimeisimmän M4-kilpailun mukaan. Tämä viittaa siihen, että

molempien lähestymistapojen yhdistäminen on lupaavin ratkaisu kysynnän ennustamiseen tulevaisuudessa (Benhamida et al. 2021). Tällaiset päätelmät viittaavat siihen, että koneoppimisella on potentiaalia olla yksi 2000-luvun mullistavimmista teknologioista. Vaikka tulevaisuutta on mahdotonta ennustaa, on olennaista, että yhteiskunta alkaa jo nyt pohtia kuinka koneoppimisen hyödyt voidaan maksimoida.

Tässä työssä huomattiin, että tekoälyn hyödyntäminen määrällisessä ennustamisessa on huomattavasti yleisempää kuin laadullisessa. Tästä syystä mielekäs ja looginen jatkotutkimusaihe voisi liittyä syvemmin laadullisen ennustamisen näkökulmaan. Lisäksi tekoälypohjaisten kysynnän ennustamisen ratkaisujen vaikutusta yrityksen resursseihin ja päätöksentekoon käsiteltiin lähdekirjallisuudessa melko vähän. Se voisi siis myös olla hyödyllinen syvällisemmän jatkotutkimuksen aihe.

LÄHTEET

- A. Aamer, L. Eka Yani, Im Alan Priyatna. (2020) Data analytics in the supply chain management: review of machine learning applications in demand forecasting. *Operations and Supply Chain Management.: International Journal* Vol.14 (1) pp. 1–13. <http://doi.org/10.31387/oscm0440281>
- Abbasimehr, H., Shabani, M., Yousefi, M. (2020). An optimized model using LSTM network for demand forecasting. *Computers & Industrial Engineering*. Vol. 143
- Abolghasemi, M., Hurley, J., Eshragh, A. & Fahimnia, B. (2020). Demand forecasting in the presence of systematic events: Cases in capturing sales promotions. *International Journal of Production Economics*, 230, 107892–. <https://doi.org/10.1016/j.ijpe.2020.107892>
- Ahamed S.F., Vijayasankar A., Thenmozhi M., Rajendar S., Bindu P. & Subha Mastan Rao T. (2023). Machine learning models for forecasting and estimation of business operations. *Journal of High Technology Management Research*, Vol. 34 (1), art. no. 100455
- Benhamida, F. Z., Kaddouri, O., Ouhrouche, T., Benaichouche, M., Casado-Mansilla, D. & López-De-Ipiña, D. (2021). Demand forecasting tool for inventory control smart systems. *Journal of Communications Software and Systems*, Vol.17(2), pp. 185-196. <https://doi.org/10.24138/jcomss-2021-0068>
- Doanh, D.C., Dufek, Z., Ejdys, J., Ginevicius, R., Korzynski, P., Mazurek, G., Paliszkiwicz, J., Wach, K. & Ziemia, E. (2023). Generative AI in the manufacturing process: theoretical considerations. *Engineering Management in Production and Services*, Vol.15(4), pp. 76-89.
- Falatouri, T., Darbanian, F., Brandtner, P., Udokwu, C. (2022). Predictive analytics for demand forecasting - a comparison of SARIMA and LSTM in retail SCM, *Procedia Computer Science*. Vol. 200 pp. 993–1003.
- Hsieh, M.-C., Giloni, A., & Hurvich, C. (2019). The propagation and identification of ARMA demand under simple exponential smoothing: Forecasting expertise and information sharing. *IMA Journal of Management Mathematics*, Vol. 31(1), pp. 307–344. <https://doi.org/10.1093/imaman/dpaa006>
- Irshadullah Asim Mohammed, R. Sofia, G V Radhakrishnan, Sarvagya Jha & Nidal Al Said. (2025). The Role of Artificial Intelligence in Enhancing Business Efficiency and Supply Chain Management. *Journal of Information Systems Engineering and Management*. <https://doi.org/10.52783/jisem.v10i10s.1413>
- Jarrahi, M.H. (2018). Artificial Intelligence and the Future of Work: Human-AI Symbiosis in Organizational Decision Making. *Business Horizons*, Vol.61(4), pp. 577-586, <https://doi.org/10.1016/j.bushor.2018.03.007>
- Jordan, M. I. & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science (American Association for the Advancement of Science)*, Vol. 349(6245), pp. 255–260. <https://doi.org/10.1126/science.aaa8415>

- Makridakis, S., Spiliotis E., Assimakopoulos, V. (2018a). Statistical and Machine Learning forecasting methods: Concerns and ways forward. PLOS ONE, vol. 13, no. 3. Available: 10.1371/journal.pone.0194889
- Makridakis, S., Spiliotis E., Assimakopoulos, V. (2018b). The M4 Competition: Results, findings, conclusion and way forward. International Journal of Forecasting, <https://doi.org/10.1016/j.ijforecast.2018.06.001>.
- Malviya P., Bhandari V. (2024) A systematic study on effective demand prediction using machine learning. Journal of Integrated Science and Technology, Vol. 12 (1), art. no. 711
- Oluyisola O.E., Bhalla S., Sgarbossa F. & Strandhagen J.O. (2022). Designing and developing smart production planning and control systems in the industry 4.0 era: a methodology and case study. Journal of Intelligent Manufacturing, Vol. 33(1), pp. 311-332.
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Taieb, S. B., Bergmeir, C., Bessa, R. J., Bijak, J. & Boylan, J. E. (2022). Forecasting: theory and practice. International Journal of Forecasting.
- Rožanec, J. M., Kažič, B., Škrjanc, M., Fortuna, B. & Mladenčić, D. (2021). Automotive OEM demand forecasting: A comparative study of forecasting algorithms and strategies. Applied Sciences, Vol.11(15).
- Sadler-Smith, E., & Shefy, E. (2004). The intuitive executive: Understanding and applying 'gut feel' in decision-making. The Academy of Management Executive, Vol. 18(4), pp. 76—91.
- Schlosser, R. W., Wendt, O., Bhavnani, S., & Nail-Chiwetalu, B. (2006). Use of information-seeking strategies for developing systematic reviews and engaging in evidence-based practice: the application of traditional and comprehensive Pearl Growing. A review. International Journal of Language & Communication Disorders, Vol. 41(5), pp. 567-582.
- Singh, A. K., Simha, J. B. & Agarwal, R. (2024). Prediction of Intermittent Demand Occurrence using Machine Learning, EAI Endorsed Transactions on Internet of Things, 10. doi: 10.4108/eetiot.5381.
- Singh S., Yadav B. & Batheri R. (2023). Industry 4.0: Meeting the Challenges of Demand Sensing in the Automotive Industry. IEEE Engineering Management Review, Vol.51(4), pp. 179-184.
- Smyl, S. (2020). A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. International Journal of Forecasting, Vol. 36(1), pp. 75–85.
- Stekler H., Symington H. (2016). Evaluating qualitative forecasts: The FOMC minutes, 2006-2010. *International Journal of Forecasting*, Vol. 32 (2), pp. 559-570.
- Stevenson, W. J. (2015). Operations management (12. ed). McGraw-Hill Education.
- Tadayonrad, Y., & Ndiaye, A. B. (2023). A new key performance indicator model for demand forecasting in inventory management considering supply chain reliability and seasonality. Supply Chain Analytics, 3. doi: 10.1016/j.sca.2023.100026

- Usuga Cadavid J.P., Lamouri S., Grabot B., Pellerin R., Fortin A. (2020). Machine learning applied in production planning and control: a state-of-the-art in the era of industry 4.0. *Journal of Intelligent Manufacturing*, Vol. 31 (6) , pp. 1531-1558.
- Vaid, S., Puntoni, S. & Khodr, A. (2023). Artificial intelligence and empirical consumer research: A topic modeling analysis. *Journal of Business Research*, 166. doi: 10.1016/j.jbusres.2023.114110
- Vallés-Pérez, I., Soria-Olivas, E., Martínez-Sober, M., Serrano-López, A. J., Gómez-Sanchís, J. & Mateo, F. (2022). Approaching sales forecasting using recurrent neural networks and transformers. *Expert Systems with Applications*, 201, 116993–. <https://doi.org/10.1016/j.eswa.2022.116993>
- Wahedi H.J., Heltoft M., Christophersen G.J., Severinsen T., Saha S. & Nielsen I.E.. (2023). Forecasting and Inventory Planning: An Empirical Investigation of Classical and Machine Learning Approaches for Svanehøj's Future Software Consolidation. *Applied Sciences*, Vol. 13 (15) , art. no. 8581
- Qu, T., Zhang, J.H., Chan, F.T.S., Srivastava, R.S., Tiwari, M.K., Park, W.-Y. (2017). Demand prediction and price optimization for semi-luxury supermarket segment, *Computers & Industrial Engineering*. Vol. 113. pp. 91–102.

LIITE A

Taulukko 6: *Tiedonhakuprosessi ja -tulokset*

Hakulause	Tulosten määrä (Scopus)	Rajausten jälkeen	Helmenkasvatus	Valittu
"industry 4.0" AND "demand forecasting"	49	12		Doanh et al. (2023), Singh et al. (2024), Singh et al. (2023)
("artificial intelligence" OR "machine learning") AND forecasting AND ("supply planning" OR "production planning")	141	27	Oluyisola et al. (2022), Rožanec et al. (2021), Tadayonrad & Ndiaye (2023), Abolghasemi et al. (2020), Ahamed et al (2023), Hsieh et al. (2019), Sadler-Smith & Shefy (2004), Makridakis et al. (2018), Smyl (2020) Makridakis et al. (2018) Vallés-pérez et al. (2022) Falatouri et al. (2022) Abbasimehr et al. (2020) Qu et al. (2017)	Petropoulos et al.(2022), Jarrahi (2018), Benhamida et al.(2021), Wahedi et al. (2023), Usuga Cadadavid et al. (2020)
("artificial intelligence" OR "machine learning") AND ("demand forecast*" OR "demand predict*") AND organization AND "decision-making"	26	10	Stekler & Symington (2016)	Irshadullah et al. (2025), Malviya & Bhandari (2024)

