



**TURUN
YLIOPISTO**
Kauppakorkeakoulu

Tekoälyn hyödyntäminen varaston optimoinnissa

Toimitusketjujen johtaminen
Kandidaatintutkielma

Laatija:
Onni Leppä

Ohjaaja:
TkT Riikka Kaipia

27.4.2026
Turku

Opiskelijan lausunto tekoölyn käytöstä tähän tutkielmaan liittyen:

En ole käyttänyt tekoölyä hyödyntäviä työkaluja tätä tutkielmaa kirjoittaessani.

Olen käyttänyt tekoölyä hyödyntäviä työkaluja tätä tutkielmaa kirjoittaessani. Tämä käyttö on dokumentoitu tutkielman liitteessä. Vakuutan, että tekoölyä käytettiin yliopiston ohjeistuksen mukaisella tavalla.

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

Kandidaatintutkielma

Oppiaine: Toimitusketjujen johtaminen

Tekijä: Onni Leppä

Otsikko: Tekoölyn hyödyntäminen varaston optimoinnissa

Ohjaaja(t): TkT Riikka Kaipia

Sivumäärä: 37 sivua + liitteet 1 sivu

Päivämäärä: 27.4.2026

Tiivistelmä

Varastonhallinta on keskeinen osa yritysten toimitusketjua, ja sen tehokkuudella on merkittävä vaikutus kilpailukykyyn, asiakastyytyvyyteen ja kustannusten hallintaan. Perinteisiä varaston optimoinnin menetelmiä on paljon, mutta ne perustuvat usein staattisiin malleihin ja oletuksiin, eivätkä ne ole kilpailukykyisiä nykyajan muuttuvissa toimitusketjuissa. Tekoöly on kehittynyt viime aikoina merkittävästi, ja sen käyttö organisaatioiden ja yritysten keskuudessa on yleistynyt. Tekoölyä on mahdollista hyödyntää varaston optimoinnissa. Sen avulla voidaan tehostaa varaston optimoinnin perinteisten menetelmien suoriutumista, ja lisäksi se tarjoaa täysin uusia sovelluksia, joita varaston optimoinnissa voidaan käyttää.

Tämän tutkielman tavoitteena on tarkastella, kuinka tekoölyä voidaan hyödyntää varaston optimoinnissa. Tutkielma pyrkii vastaamaan kysymyksiin siitä, kuinka tekoölyn avulla voidaan tehostaa varaston optimoinnin perinteisten menetelmien suoriutumista, ja mitä uusia mahdollisuuksia se tuo varastonhallintaan. Tutkielma toteutettiin kirjallisuuskatsauksena, ja lähteinä käytettiin alan tieteellistä kirjallisuutta.

Tutkielman keskeisimpien havaintojen perusteella voidaan todeta, että merkittävimmät tekoölyn tuomat edut liittyvät kysynnän ennustamiseen tehostamiseen. Mitä tarkemmin yritys pystyy ennustamaan asiakkaidensa kysyntää, sitä optimaalisempia tilauksia se voi tehdä, jolloin se pystyy välttämään yli- ja alivarastojen syntymisen. Myös täydennystilauksien tekeminen voidaan automatisoida ja optimoida tekoölyn avulla. Uudet tekoölyn tuomat mahdollisuudet varaston optimointiin liittyvät pitkälti varaston operatiivisen toiminnan tehostamiseen. Tavaroiden hyllytys, keräily ja sijoittelu varaston sisällä voidaan optimoida tekoölyn avulla, esimerkiksi minimoimalla niihin käytettävää aikaa ja etäisyyksiä tai käyttämällä älykkäitä robotteja ja lentäviä drooneja, jotka pystyvät liikkumaan ihmisiä nopeammin sekä ketterämmin.

Etujen lisäksi tekoölyn käyttöön liittyy myös haasteita. Tekoölyn käyttöönotto vaatii yrityksiltä suuria investointeja muun muassa uusiin järjestelmiin, datainfrastruktuurin kehittämiseen ja asiantuntijoiden palkkaamiseen. Tekoöly voi herättää myös muutosvastarintaa työntekijöissä, ja heitä pitää kouluttaa paljon uusien järjestelmien käyttöön ja uusien toimintatapojen ymmärtämiseksi.

Tutkielman tulosten ja havaintojen perusteella voidaan todeta, että tekoölyn käytön hyödyt ovat merkittävämpiä kuin siitä aiheutuvat haasteet, ja että yritysten on kannattavaa ottaa tekoöly käyttöön ja tehdä sitä varten investointeja. Tekoölyn rooli varaston optimoinnissa ja toimitusketjujen hallinnassa tulee tulevaisuudessa kasvamaan huomattavasti, ja yritysten on pystyttävä omaksuma sen käytännöt pysyäkseen mukana nopeasti kiihtyvässä kilpailussa.

Avainsanat: varastonhallinta, varaston optimointi, tekoöly, koneoppiminen, syväoppiminen, keinotekoiset neuroverkot, kysynnän ennustaminen, toimitusketjut

SISÄLLYS

1	Johdanto	7
1.1	Tutkielman tavoite ja rakenne	8
2	Varaston optimointi	9
2.1	Perinteisiä varaston optimoinnin menetelmiä	9
2.1.1	Taloudellisen tilauserän malli (EOQ)	9
2.1.2	Tilauspiste (ROP)	11
2.1.3	Just-in-Time -menetelmä (JIT)	12
2.1.4	Varmuusvarasto	13
2.1.5	ABC-analyysi	14
2.1.6	Toimittajan hallinnoima varasto (VMI)	14
2.2	Varastoinnin kustannukset	16
2.2.1	Tilaukustannukset	16
2.2.2	Pääomakustannukset	17
2.2.3	Puutekustannukset	17
3	Tekoäly	19
3.1	Tekoälyn tasot	19
3.1.1	Neuroverkot	20
3.1.2	Koneoppiminen	21
3.1.3	Syväoppiminen	22
4	Tekoälyn hyödyntäminen varaston optimoinnissa	24
4.1	Kysynnän ennustaminen	24
4.2	Älykkäät täydennystilaukset	27
4.3	Varaston operatiivisen toiminnan kehittäminen	28
4.4	Tekoälyn haasteet varaston optimoinnissa	30
5	Yhteenveto ja johtopäätökset	32
	Lähteet	35
	Liitteet	38
	Liite 1 Selvitys tekoälyn käytöstä	38

KUVIOT

Kuvio 1. Taloudellisen tilauserän malli (mukaillen Agarwal 2014)	10
Kuvio 2. Jatkuvan seurannan ja periodiseurannan vertailua (mukaillen Agarwal 2014)	12
Kuvio 3. Piiskavaikutus (mukaillen Lee ym. 1997)	16
Kuvio 4. Tekoälyn tasot (mukaillen Kreutzer & Sirrenberg 2020)	20
Kuvio 5. Neuroverkot (mukaillen Kreutzer & Sirrenberg 2020)	20
Kuvio 6. Tekoälyn hyödyntäminen varaston optimoinnissa LSTM-mallin avulla (mukaillen Ma ym. 2024)	25

TAULUKOT

Taulukko 1. Tekoälyn käytön hyödyt (mukaillen Ma ym. 2024)	26
--	----

1 Johdanto

Varastonhallinta on yrityksille tärkeä funktio ja olennainen osa niiden toimitusketjuja. Kaupankäynnin volyymit ovat erittäin suuria ja ne kasvavat koko ajan. Asiakkaat odottavat, että heidän haluamansa tuotteet olisivat heti saatavilla. Yrityksen kyvyllä hallita varastoaan, ja siten vastata asiakkaidensa kysyntään oikealla tavalla, voi olla positiivisia vaikutuksia sen avainmittareihin, ja sitä kautta myös sen menestymiseen kilpailijoita vastaan (Li ym. 2025). Yrityksen täytyy pystyä toimitamaan tuotteensa asiakkaalle, silloin kun tämä tekee tilauksen. Varastossa tulee siis olla aina tarpeeksi kyseistä tuotetta. Tuotetta ei saa kuitenkaan olla varastossa liikaa, sillä tällöin varastointikustannusten määrä kasvaa turhaan. Hyvin organisoidussa varastonhallintajärjestelmässä yhdistyy siis tehokkuus sekä tuotteiden riittävä saatavuus (Bhavikatta 2025).

Viime vuosien aikana tekoälyn (engl. AI, Artificial Intelligence) merkitys on kasvanut huomattavasti. Tekoälystä on tullut arkipäivää tavallisille ihmisille esimerkiksi erilaisten ”chatbot” -palveluiden myötä, mutta yhä enenevässä määrin myös yritykset ottavat sitä käyttöön ja yrittävät integroida sitä järjestelmiinsä, jotta saisivat tehostettua sekä optimoitua prosessejaan paremmiksi. Stanfordin yliopiston tekemän raportin ”The 2025 AI Index Report” (Gil & Perrault 2025) mukaan vuonna 2024 78 % yksityisistä yhdysvaltalaisista yrityksistä käytti tekoälyä ainakin yhdessä toiminnossaan. Sama luku oli 50 % vuonna 2020 ja 20 % vuonna 2017. Käyttöaste on siis kasvanut paljon. Tekoälyyn myös investoidaan erittäin paljon. Edellä mainitut yritykset käyttivät tekoälyinvestointeihin yli sata miljardia dollaria vuonna 2024. Tällä hetkellä tekoälyn osaaminen voi luoda yrityksille kilpailuetua, mutta tulevaisuudessa se tulee kuitenkin todennäköisesti muuttamaan koko kansainvälisen kaupan toimintatavat ja -mallit, ja sen takia yritysten on välttämätöntä opetella ymmärtämään sen merkitys sekä sen tuomat mahdollisuudet.

Nyky maailman kehittyvä kaupankäynti ja digitalisaation nopea kehitys vaatii yrityksiltä tehokasta toimitusketjujen ja varastonhallintaa, mutta se myös samalla antaa niille paljon mahdollisuuksia kehittyä ja keksiä uusia keinoja toiminnan parantamiseksi. Tekoäly on yksi kehityksen mahdollistajista. Sen avulla yritys pystyy tehostamaan varastojensa hallintaa ja optimoimaan varastotasojaan käyttämällä erilaisia järjestelmiä, algoritmeja ja koneita. Tekoälyä hyödyntämällä pystytään muun muassa ennustamaan asiakkaiden kysyntää paremmin ja täten pitämään varastotasot täsmällisempinä, tai optimoimaan varaston sisällä tapahtuvaa operatiivista toimintaa nopeammaksi ja tehokkaammaksi. Tekoälyn tuoman automaation ja yleisesti paremman varaston optimoinnin ansiosta on myös mahdollista tehdä kustannussäästöjä. (Li ym. 2025.)

1.1 Tutkielman tavoite ja rakenne

Tämän tutkielman menetelmä on kirjallisuuskatsaus, ja lähteinä on käytetty alan tieteellistä kirjallisuutta, kuten artikkeleita ja kirjoja. Tavoitteena on tarkastella erilaisia tapoja, joilla tekoälyä voidaan hyödyntää varaston optimoinnissa. Tutkielmassa tarkastellaan muun muassa keinoja, joiden avulla perinteisten varastoinnin ja varaston optimoinnin menetelmien käytöstä saadaan helpompaa, nopeampaa sekä kustannustehokkaampaa. Lisäksi tarkastellaan aivan uusia varaston optimoinnin keinoja, joita tekoäly mahdollistaa. Tekoäly muovaa varastonhallintaa jatkuvasti, ja uusia teknologioita kehitetään koko ajan lisää. Lin ym. (2025) mukaan alalle ei kuitenkaan ole vielä muodostunut selkeitä toimintamalleja tai käytänteitä, joiden mukaan olisi tehokkainta toimia, mikä muodostaa tutkimusaukon. Tutkielmassa pyritään siten tekemään myös uusia johtopäätöksiä olemassa olevan kirjallisuuden perusteella.

Tutkielma pyrkii vastaamaan seuraaviin tutkimuskysymyksiin:

- Miten varastoinnin ja varaston optimoinnin perinteisten menetelmien suoriutumista voidaan kehittää tekoällyn avulla?
- Mitä uusia keinoja sekä teknologioita tekoäly tuo varastointiin ja varaston optimointiin?

Tutkielmassa on viisi päälukua. Johdannon jälkeen toisessa luvussa tutustutaan varastonhallinnan peruskäsitteisiin ja perinteisiin varaston optimoinnin keinoihin, joita pystyy hyödyntämään ilman tekoälyä. Kolmannessa luvussa käydään läpi tekoällyn käsitettä ja siihen liittyvää teoriaa. Luvussa tarkastellaan tekoällyn yleisiä käytäntöjä ja toimintamalleja. Neljäs luku eli pääluke yhdistelee kahta aiempaa aihetta, ja siinä käydään läpi konkreettisia tapoja, joilla tekoälyä voitaisiin hyödyntää varaston optimoinnissa. Lisäksi tarkastellaan haasteita, joita tekoällyn käyttö ja käyttöönotto voi aiheuttaa. Viidennessä luvussa tehdään yhteenveto ja esitellään tutkielmasta tehtyjä johtopäätöksiä.

2 Varaston optimointi

Varastonhallinnalla tarkoitetaan yritykseen saapuvien ja siitä lähtevien materiaalivirtojen hallintaa. Se sisältää esimerkiksi varastotasojen seuraamista, tavaroiden vastaanottamista ja lähettämistä sekä tavaroiden hyllytystä ja keräilyä. Varaston optimointi sen sijaan tarkoittaa varastotasojen hallintaa. Siinä käytetään työkaluna usein data-analytiikan keinoja ja tavoitellaan tilannetta, missä varastossa olisi aina oikea määrä tavaraa. Lisäksi optimoinnilla pyritään kehittämään edellä mainittuja varaston päivittäisiä operatiivisia prosesseja, ja tekemään niistä mahdollisimman tehokkaita. (Jean 2024.) Tämän luvun tarkoituksena on käsitellä varastoinnin peruskäsitteitä sekä varaston optimoinnin perinteisiä menetelmiä. Lisäksi tarkastellaan varastoinnista aiheutuvia kustannuksia.

Varastoinnilla voi olla merkittävä vaikutus yrityksen toimitusketjuun, ja sitä kautta kustannusrakenteeseen sekä asiakassuhteisiin (Majahar Ali ym. 2025). Jos varastossa ei ole tarpeeksi tavaraa silloin, kun asiakas haluaisi tilata tuotteet, se vähentää myynnin määrää. Pahimmassa tapauksessa asiakas saatetaan menettää, jos tämä vaihtaa kokonaan toimittajaa. Jos tavaraa on sen sijaan liikaa, se kasvat-
taa varastoinnin kustannuksia, muun muassa pääomakustannuksia. Tavoitteena olisi siis pitää yllä sellaisia varastotasoja, että pystyttäisiin välttämään yli- ja alivarastojen syntyminen. Varaston optimoinnilla voidaan yleisesti alentaa varastoinnin kustannuksia ja tehdä varaston toiminnasta tehokkaampaa, jolloin myös asiakkaiden palvelutaso pysyy korkeampana.

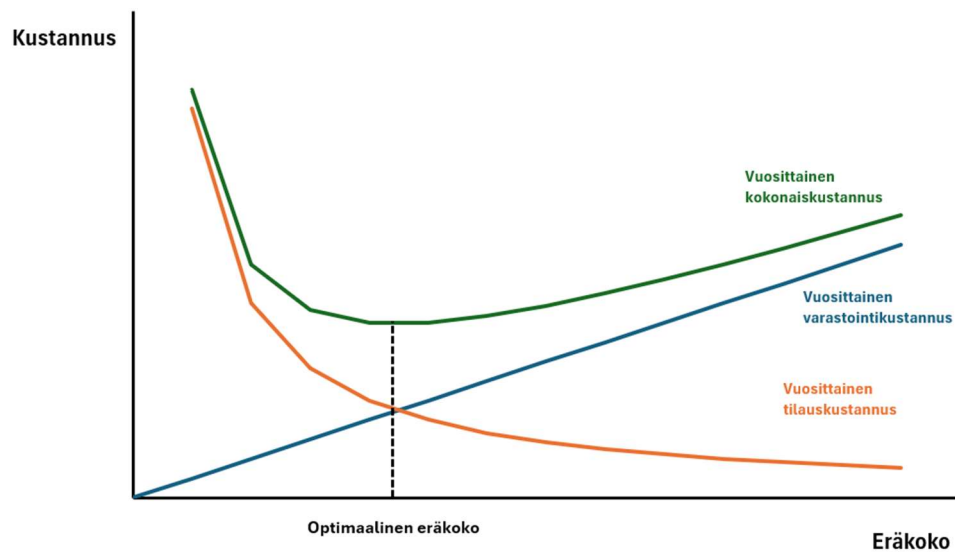
2.1 Perinteisiä varaston optimoinnin menetelmiä

Varaston optimointiin on paljon erilaisia menetelmiä ja mittareita. Usein keskeisenä ongelmana optimoinnissa on se, kuinka paljon tavaraa kannattaisi tilata kerralla, ja kuinka usein tilauksia kannattaisi tehdä. Lisäksi varastoja voidaan automatisoida, jolloin prosesseista, kuten hyllytyksestä ja keräilystä tulee tehokkaampia. Perinteiset menetelmät perustuvat usein historiallisen datan analysointiin sekä erilaisiin staattisiin malleihin (engl. static model), eli malleihin, joissa tietyn mittarin oletetaan pysyvän muuttumattomana. Nykyään globaalit toimitusketjut ovat kuitenkin niin alttiita äkillisille muutoksille ja häiriöille, että perinteisten menetelmien käyttö voi helposti johtaa harhaanjohtaviin tuloksiin. (Li ym. 2025.)

2.1.1 Taloudellisen tilauserän malli (EOQ)

Taloudellisen tilauserän mallin (engl. EOQ, Economic Order Quantity) avulla voi määrittellä sen, kuinka suuri erä kannattaa tilata kerralla. Se ottaa huomioon varastointi- sekä tilauskustannukset ja pyrkii löytämään tasapainon niiden välillä, eli toisin sanoen minimoimaan kokonaiskustannukset.

(Agarwal 2014.) Kuvio 1 hahmottelee taloudellisen tilauserän mallia ja kustannusten tasapainottamista.



Kuvio 1. Taloudellisen tilauserän malli (mukaillen Agarwal 2014)

Vuosittaiset varastointikustannukset ovat sitä suuremmat mitä suurempi eräkkö tilataan eli mitä harvemmin tilataan, sillä tuotteet ovat tällöin varastossa pidemmän aikaa. Sen sijaan tilauskustannusten määrä kasvaa sitä enemmän, mitä pienempi eräkkö tilataan eli mitä useammin tilauksia tehdään. Optimaalinen eräkkö löytyy käyrien leikkauskohdasta. Siinä kokonaiskustannukset ovat pienimmillään.

Kokonaiskustannukset muodostuvat siis tilaus- ja varastointikustannuksista. Optimaalinen tilauserän koko voidaan määrittää myös matemaattisesti, ja se saadaan, kun muodostetaan kokonaiskustannuksista funktio ja derivoidaan se eräkköön suhteen. Tällöin saadaan selville funktion pienin arvo eli tilauserä, missä kustannukset ovat pienimmät. Harrison ym. (2019) esittävät kirjassaan oheisen kaavan, jolla EOQ voidaan laskea:

$$EOQ = \sqrt{\frac{2zC_s}{cC}}$$

missä

- z = kysyntä tietyssä ajanjaksona
- C_s = tilauskustannus


- cC = yhden yksikön varastointikustannus tietyssä ajanjaksona.

EOQ on erittäin perinteinen varaston optimoinnin muoto, jota on käytetty jo vuosikymmeniä. Se ei kuitenkaan ota huomioon monia sellaisia tekijöitä, joita esiintyy nykypäivän toimitusketjuissa. EOQ:n laskemiseksi täytyy tehdä monia oletuksia. Täytyy esimerkiksi olettaa, että kysyntä, toimitusaika ja tilaus- sekä varastointikustannukset pysyvät koko ajan vakiona. Lisäksi täytyy olettaa, että tilauskoko ja varaston kapasiteetti ovat rajattomia. EOQ ei myöskään ota huomioon materiaalikustannuksia, vaan niiden oletetaan pysyvän vakiona. Suuria eriä tilaamalla on usein mahdollista saavuttaa skaalaetuja, jolloin materiaalien yksikkökustannukset ovat pienemmät. Varastossa olevien materiaalien arvolla on lisäksi vaikutus suoraan varastointikustannuksiin.

2.1.2 Tilauspiste (ROP)

Taloudellisen tilauserän mallissa tarkoituksena on siis selvittää, kuinka paljon tavaraa kannattaisi tilata kerralla. Jotta varastotasoa saataisiin optimoitua vielä enemmän, täytyy määrittää milloin tilaus olisi optimaalisinta tehdä. Sen voi määrittää tilauspisteen (engl. ROP, Reorder Point) avulla. ROP:n tavoitteena on määrittää sellainen tilauksentekohetki, että uusi erä saapuisi varastoon mahdollisimman samaan aikaan, kun vanha tavara loppuu. Näin pyritään välttämään tilanteet, joissa varastoa on liikaa tai liian vähän. (Nobil ym. 2020.) Tilauspiste riippuu siis lähtökohtaisesti kahdesta tekijästä: tavaroiden toimitusajasta ja kysynnästä sen aikana.

ROP:n määrittämistä varten tarkastellaan usein varastotason kehitystä tai viime tilauksesta kulunutta aikaa. Yksi vaihtoehto uuden tilauksen tekemiseen on seurata varastotasoa jatkuvasti, ja tehdä tilaus silloin, kun varasto saavuttaa jonkin ennalta määrätyn tason (engl. continuous review system). Tilauksen eräkoko on siis aina vakio, sillä täydennyksellä pyritään aina samaan tavoitetasoon. Toisena vaihtoehtona on käyttää periodiseurantaa (engl. periodic review system), eli tarkistaa varastotasot tietyin väliajoin ja tehdä täydennystilaus riippuen silloisesta tasosta. Tällöin tilausten välinen aika on aina vakio. Jos tilauksia tehdään usein, välillä edellinen erä ei välttämättä ole vielä saapunut, kun uutta tilausta jo tehdään. Tämän takia ROP:n määrittämisessä on tärkeää ottaa huomioon sen hetkisten varastotasojen lisäksi myös matkalla olevat tavarat. Kuvio 2 havainnollistaa jatkuvan seurannan ja periodiseurannan välisiä eroja.



Kuvio 2. Jatkuvan seurannan ja periodiseurannan vertailua (mukaien Agarwal 2014)

Menetelmä kannattaa valita sen perusteella, minkälaisesta tuotteesta on kyse (Silver ym. 2017). Tuotteille, joiden kysyntä on helpommin ennustettavissa, on kannattavampaa käyttää periodiseurantaa. Tällöin on helppo päättää jokin ajanjakso, jonka välein täydennystilauksia tehdään. Periodiseurantaa kannattaa käyttää myös silloin, jos monia tuotteita tilataan samalta toimittajalta tai jos ne toimitetaan samalla kuljetuksella. Tällöin on mahdollista hallita paremmin toimittajasuhteisiin sekä kuljetuksiin liittyviä kustannuksia, jolloin voidaan myös saavuttaa skaalaetuja. Jatkovaa seurantaa sen sijaan kannattaa käyttää tuotteille, joiden kysyntä on epävakaata ja vaikeasti ennustettavissa. Tällöin äkilliset muutokset kysynnässä eivät haittaa, kun täydennystilauksia pystytään tekemään tehokkaasti heti, kun varastotaso saavuttaa tietyn pisteen. Välillä käytetään myös niin kutsuttua hybridimenetelmää, jossa yhdistellään molempien menetelmien piirteitä (Agarwal 2014). Varastotasoa voidaan esimerkiksi tarkistaa tietyin väliajoin, mutta tilaus tehdään vain silloin, jos varastotaso on saavuttanut sovitun pisteen. Kun tilaus lopulta tehdään, määrä saatetaan kuitenkin pitää vakiona, jolloin varaston tavoitetasoa ei välttämättä saavuteta, jos kysyntä on ollut suurta periodien välillä.

2.1.3 Just-in-Time -menetelmä (JIT)

Just-in-Time -menetelmässä (JIT) tavoitteena on minimoida varasto, ja tilata tuotteet siten, että ne saapuvat juuri kun edelliset loppuvat. Niin kutsuttujen nollavarastojen avulla on mahdollista vähentää varastointiin liittyviä kustannuksia. JIT:ssä varaston kierto on erittäin nopeaa eli varasto kuluu loppuun nopeasti ja uusia eriä saapuu jatkuvasti. Tällöin varastoon sitoutuu kerrallaan vain vähän pääomaa, jolloin varastointikustannukset ovat pienemmät. Lisäksi materiaalienhallinnassa ja -tarkastuksissa sekä varastotasojen seuraamisessa on mahdollista tehdä kustannussäästöjä, kun työvoimaa tarvitaan vähemmän. (Kros ym. 2006.) JIT:n avulla pystytään vähentämään huomattavasti myös materiaalien hallintaan kuluva aika, kun tavarat saapuvat suoraan tuotantoalueelle, eikä varastoon, mistä ne pitäisi myöhemmin joka tapauksessa siirtää sinne.

Perinteisissä tuotantomenetelmissä käytetään usein työntöohjausta (engl. push control) eli tavaraa tuotetaan varastoon suuria määriä, jossa ne odottavat asiakkaiden tilauksia. Tuotantomäärät perustuvat ennustettuun kysyntään. Työntöohjauksessa hyödynnetään siis varasto-ohjautuvaa tuotantoa (engl. MTS, Make to Stock). JIT-lähtöisessä tuotannossa käytetään sen sijaan imuohjausta (engl. pull control). Siinä materiaalit hankitaan toimittajilta ja tuote valmistetaan asiakkaalle vasta silloin kun kysyntää todella ilmenee. Tuotteita valmistetaan siis tilauksesta (engl. MTO, Make to Order). (Kros ym. 2006.)

Jotta varastotasot voidaan pitää minimissä, uusia tilauksia täytyy tehdä jatkuvasti ja toimitusten tulee olla nopeita sekä täsmällisiä. JIT:ssä onkin keskeistä, että yrityksellä on muutamia luotettavia toimittajia, jotka kykenevät täyttämään yrityksen varastoja tehokkaasti. On myös tärkeää, että informaatio yritysten välillä liikkuu nopeasti ja selkeästi. (Kros ym. 2006.) JIT toimii hyvin sellaisessa tilanteessa, missä kysyntä on säännöllistä ja sitä on mahdollista ennustaa (Harrison ym. 2019). Esimerkiksi autovalmistaja Ford on pyrkinyt tekemään autojensa rungoista mahdollisimman yksinkertaisia, jolloin niiden kysyntää on helpompi ennustaa, ja vasta kokoamisvaiheessa se räätälöi autoistaan erilaisia versioita. Tällöin auton perusrunko on jo kasassa, ja suurin osa räätälöintiin tarvittavista osista on saapunut paikalle. Osien kasaaminen yhteen on huomattavasti nopeampaa kuin kokonaisen auton rakentaminen, eli tällä menetelmällä Ford pystyy vastaamaan muuttuvaan kysyntään paljon tehokkaammin.

2.1.4 Varmuusvarasto

Monissa perinteisissä varastoinnin optimoinnin menetelmissä tehdään paljon oletuksia. Esimerkiksi kysynnän ja toimitusaikojen oletetaan usein pysyvän vakiona. Kuten aiemmin on kuitenkin käynyt ilmi, monesti kysyntä vaihtelee paljon ja se on usein arvaamatonta. Tällöin yrityksen olisi syytä pitää yllä varmuusvarastoa (engl. safety stock). Sen tarkoituksena on, että varastoon tilataan hieman suunniteltua suurempia määriä, jotta siellä olisi aina pieni määrä tavaraa siltä varalta, että kysyntä olisi ennustettua suurempaa. Varmuusvarasto ei ole vakio vaan se riippuu kysynnän ja toimitusaikojen epävarmuudesta. Mitä enemmän epävarmuutta ilmenee, sitä tärkeämpää varmuusvaraston määrittäminen on. Optimaalisin tilanne tietenkin olisi, jos uusi tilaus saapuisi aina vanhan varaston loppuessa eli päästäisiin lähelle JIT-mallia. Varmuusvarastot ovat kuitenkin keskeisessä osassa kaikkia toimitusketjuja. Gonçalvesin ym. (2020) mukaan varmuusvarastot ovat yksi tehokkaimmista tavoista hallita kysynnän sekä toimitusaikojen epävarmuutta, ja mikään toimitusketju ei toimi kunnolla ilman niitä.

Varmuusvarastoa määriteltäessä yrityksen kannattaa pohtia minkälaista palvelutasoa he haluavat pitää yllä. Yrityksen on olennaista tarkastella suhdetta tuotteen loppumisen ja varastointikustannusten välillä. (Demiray KIRMIZI ym. 2024.) Jos varastointikustannukset ovat korkeita, ei suurta varmuusvarastoa ole kannattavaa pitää. Tällöin palvelutaso on matala ja riski puutetilanteelle (engl. stockout) kasvaa. Tällä tarkoitetaan tilannetta, jossa varastosta loppuu tavara eikä asiakkaan kysyntään pystytä vastaamaan. Jos varaston loppuminen sen sijaan aiheuttaa negatiivisia vaikutuksia yrityksen toimintaan, sen pitäisi pyrkiä korkeampaan palvelutasoon, ja varmuusvarastoa tulisi olla enemmän.

2.1.5 ABC-analyysi

Usein yrityksen varastossa on todella monia varastonimikkeitä (engl. SKU, Stock Keeping Unit), ja tällöin niiden hallinta voi olla haasteellista. Helposti voisi luulla, että jos myyntiä on paljon ja varaston kierto on nopeaa, niin varastonhallinta toimii hyvin. On kuitenkin yleistä, että varastossa on paljon sellaisia nimikkeitä, jotka eivät tuota kovin paljon lisäarvoa yritykselle.

Varastonimikkeiden hallinnan tehostamiseksi voidaan hyödyntää ABC-analyysia. Se perustuu Pareton periaatteeseen, jossa 80 % jonkin ilmiön seurauksista johtuu 20 %:sta sen syistä. Menetelmän tarkoituksena on analysoida varastonimikkeitä ja jaotella ne kolmeen kategoriaan A, B ja C. Jako tehdään sen perusteella, kuinka suuri merkitys kullakin varastonimikkeellä on yrityksen kannattavuuteen. Eräässä tutkimuksessa havaittiin, että varastossa kategoriaan A kuuluvien tuotteiden osuus oli vain 18 %, mutta ne tuottivat jopa 78 % kaikista tuotoista. Kategoriaan B kuuluvien tuotteiden osuus sen sijaan oli 23 % ja ne tuottivat 16 % kokonaistuotoista. (Ray Silaen ym. 2024.) Kategoriaan C kuului siis yli puolet varaston tuotteista, mutta niiden osuus yrityksen tuotoista oli vain muutaman prosentin verran.

Jaottelun jälkeen määritellään, miten varastonohjausta toteutetaan kunkin kategorian osalta. Eri kategorioissa voidaan käyttää erilaisia täydennysmenetelmiä. Esimerkiksi kategoriaan A kuuluvat tuotteet sitouttavat varastoon paljon pääomaa ja niiden kierto varastossa olisi hyvä olla mahdollisimman nopeaa. Tällaisten tuotteiden kohdalla kannattaa käyttää jatkuvaa seurantaa ja tehdä täydennystilauksia aina, kun varastotaso saavuttaa tietyn pisteen. C-kategorian tuotteissa kannattaa sen sijaan hyödyntää periodiseurantaa.

2.1.6 Toimittajan hallinnoima varasto (VMI)

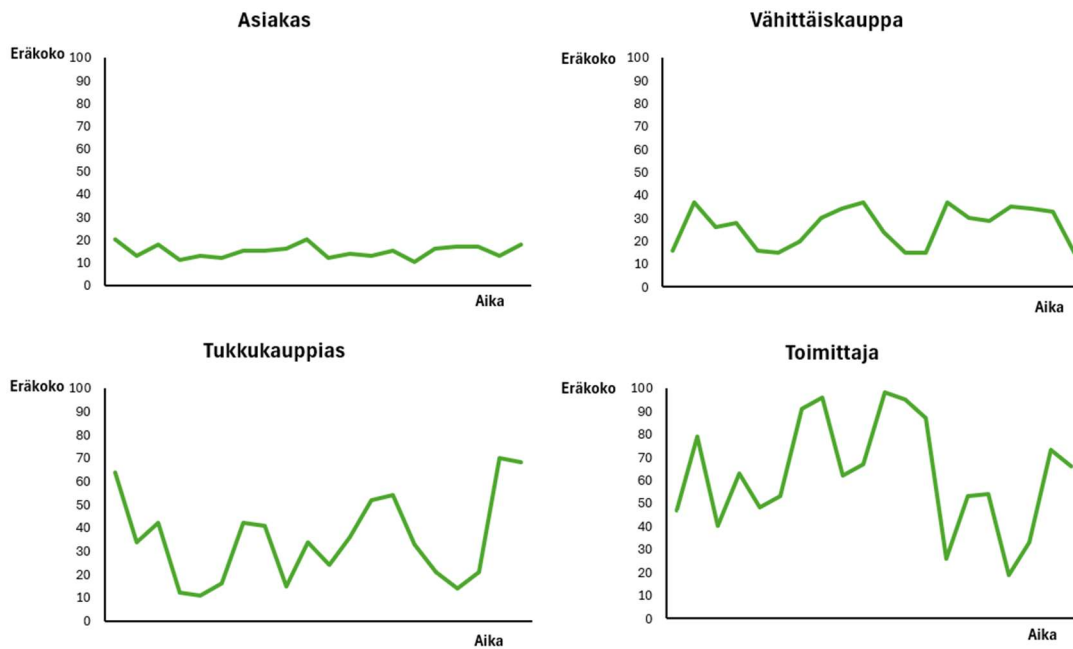
Toimittajan hallinnoimalla varastolla (engl. VMI, Vendor Managed Inventory) tarkoitetaan tilannetta, missä yritys ei itse hoida varastonsa hallintaa vaan ulkoistaa sen toimittajalleen. Käytännössä

toimittaja lähettää tuotteet asiakkaalle, kun tämän varastotaso laskee sen sijaan, että asiakas itse tekisi täydennystilauksen. Tavoitteena on yleensä säästää varastointikustannuksissa ja samalla parantaa palveluastetta. VMI on erittäin tärkeä osa yrityksen toimitusketjun hallintaa, ja suurin osa suurista yrityksistä hyödyntää sitä omassa varastonhallinnassaan. (van den Bogaert & van Jaarsveld 2021.)

VMI:ssä toimittaja on siis vastuussa täydennyksien tekemisestä, mutta täydennysmenetelmät ja -perusteet sekä muutkin varastointiin liittyvät asiat on sovittava etukäteen osapuolten välillä. Asiakas voi esimerkiksi määrittää varastolleen ylä- ja alarajat, joiden välissä saldon pitäisi pysyä, ja tason tai ajankohdan, jolloin täydennys tulisi tehdä. Myös tavaroiden omistajuus on keskeinen seikka, josta pitää sopia. Myyjä voi esimerkiksi omistaa tavarat siihen asti, että asiakas myy ne eteenpäin, vaikka se olisikin jo toimittanut ne asiakkaan varastoon. Varastointi sitoo paljon käyttöpääomaa ja asiakkaan on mahdollista vähentää siitä syntyviä pääomakustannuksia pitämällä tuotteet mahdollisimman pitkään myyjän omistuksessa. Tällöin myyjä voi laskuttaa asiakasta vasta silloin, kun tuotteet on myyty. Omistajuuden lisäksi tavaroiden sijainnilla voi vaikuttaa siihen, millaista VMI-mallia käytetään. Varasto voi sijaita tavaroiden omistajuudesta riippumatta eri sijainneissa, muun muassa myyjän, asiakkaan tai 3PL-toimijan eli ulkoisen logistiikkaoperaattorin tiloissa.

Jotta VMI-malli toimii, on tärkeää, että osapuolten välinen kommunikaatio on aktiivista ja toiminta läpinäkyvää. Toimittajan olisi hyvä saada pääsy asiakkaan kysyntään sekä tilauksiin liittyvään dataan, ja saada se integroitua omiin järjestelmiinsä. (Harrison ym. 2019.) Näin toimittaja pystyy tekemään täydennystilauksia tehokkaammin ja paremmalla tarkkuudella. Läpinäkyvyys osapuolten välillä on tärkeää myös sen takia, että yritys pystyy paremmin tarkkailemaan ja arvioimaan toimittajiensa toimintaa. Tällöin yhteistyö on sujuvampaa, ja yrityksen on helpompi vaihtaa toimittaja toiseen, jos tämä ei kykene täyttämään kaikkia vaatimuksia tarpeeksi hyvin. (van den Bogaert & van Jaarsveld 2021.)

Huono kommunikaatio ja datan jakaminen voi johtaa häiriöihin toimitusketjun eri portaissa, eikä kysyntää pystytä ennustamaan lainkaan. Tietämättömyys luo epävarmuutta, ja usein yritykset tilaavat mieluummin hieman enemmän tavaraa kuin liian vähän. Jos kaikki toimijat tilaavat aina hieman enemmän tavaraa, toimitusketjun loppupäässä tilausmäärät voivat vaihdella paljon ja kasvaa aivan liian suuriksi, vaikka loppuasiakkaan kysyntä olisi tasaista. Tällaista tilannetta kutsutaan piiskavaikutukseksi (engl. bullwhip effect). (Lee ym. 1997.) Se voi johtaa samanaikaisesti liian suuriin varastoihin sekä huonoon asiakkaiden palveluasteeseen. Kuvio 3 havainnollistaa piiskavaikutusta.



Kuvio 3. Piiskavaikutus (mukaillen Lee ym. 1997)

2.2 Varastoinnin kustannukset

Varastointi aiheuttaa yrityksille paljon kustannuksia, ja esimerkiksi monien teollisuusyritysten suurin omaisuuserä koostuu nimenomaan varastoista (Gurtu 2021). Al-hamadanin ja Al-Darrajin (2025) mukaan Yhdysvalloissa varastointiin liittyvien kustannusten osuus kaikista logistiikkakustannuksista on 30 %. Osa kustannuksista on suoria, mutta paljon syntyy myös epäsuoria kustannuksia, jotka voivat helposti jäädä huomioimatta. Kustannuksia syntyy muun muassa tuotteiden tilaamisesta, niiden pitämisestä varastossa ja tilanteissa, joissa tuotteita ei pystytäkään myymään asiakkaille. Tehokkaalla varaston optimoinnilla kustannuksia pystyy kuitenkin hallitsemaan, ja säästöjä on mahdollista tehdä.

2.2.1 Tilaukset

Jotta varastoon saadaan tuotteita, niitä täytyy tilata. Tilauksia on välttämätöntä tehdä, mutta niistä syntyviin kustannuksiin on mahdollista vaikuttaa tarkkailemalla tilausmääriä sekä -aikoja. Kuljetuskustannukset ovat keskeinen osa tilauksetkustannuksia. Kuljetuksen hinta on usein vakio riippumatta siitä, onko esimerkiksi kontti tai muu vastaava kuljetustapa täyteen vai vain osittain lastattu. Kuljetuksen yksikkökustannuksissa voidaan kuitenkin saavuttaa skaalaetuja, sillä ne ovat sitä pienempiä, mitä suurempia volyymeja tilataan. Usein myös materiaalikustannuksissa voidaan saavuttaa skaalaetuja, jos jotain tuotetta tilataan kerralla suurina määrinä. Jos tilaus täytyy tehdä manuaalisesti, siitä syntyy henkilöstökustannuksia. Myös tilauksen vastaanottamisesta ja purkamisesta aiheutuu

kustannuksia. Ne aiheuttavat niin ikään henkilöstökustannuksia ja/tai vastaavasti konekustannuksia, mikäli varaston vastaanotto ja hyllytys on automatisoitu. (Chopra 2019.)

2.2.2 Pääomakustannukset

Suorien kustannusten, kuten tilauskustannusten lisäksi varastointiin liittyy myös sellaisia kustannuksia, joista ei suoraan aiheudu rahavirtoja. Tällaisia ovat esimerkiksi varastointikustannukset eli kustannukset, jotka syntyvät siitä, kun tavaroita pidetään varastossa. Varastoon sitoutuu paljon pääomaa, ja joillakin yrityksillä suurin osa niiden pääomasta saattaa koostua vaihto-omaisuudesta ja varastosta. Varaston ylläpitäminen on vaihtoehtoiskustannus sille, että yritys sijoittaisi pääomaansa johonkin muuhun tarkoitukseen, ja yritys ottaa täten riskin, kun se pitää yllä varastoja. Riski on sitä suurempi, mitä pidempään tavarat viettävät aikaa varastossa eli mitä pidempään pääoma on sitoutunut. (Krajewski & Malhotara 2022.) Riskiin vaikuttaa myös se, kuinka hyvin yritys pystyy hallitsemaan käyttöpääomasykliään (engl. CCC, Cash Conversion Cycle). Se mittaa kuinka monta päivää kuluu toimittajalle maksun ja asiakkaalta maksun saamisen välillä eli toisin sanottuna sitä, kuinka pitkään pääoma on sitoutunut varastoon. (Wang 2019.) Yrityksen riski kasvaa, jos sen käyttöpääomasykli on pitkä, jolloin se voi joutua ottamaan lyhytaikaisia lainoja rahoittaakseen varaston ylläpitoa.

Suuren sitoutuneen pääoman ja siten riskin ottamisen myötä yritykset usein hankkivat varastolleen vakuutuksia. Vakuutusmaksut ovat luonnollisesti sitä suurempia, mitä suurempi varaston arvo on. Verot voivat myös kasvaa suuren varaston takia, sillä yrityksen verotettavaan tuloon vaikuttaa varaston arvo. Lisäksi kustannuksia voi syntyä vuokranmaksuista, jos yritys ei omista varastotiloja. Välillä yritykset saattavat vuokrata tietyn osuuden varastotilasta. Tällöin vuokran suuruus riippuu vuokratavan varastotilan koosta. (Krajewski & Malhotara 2022.)

2.2.3 Puutekustannukset

Puutekustannuksia aiheutuu myynnin menetyksistä eli tilanteissa, joissa yritys ei kykene vastaamaan asiakkaidensa kysyntään tai myymään heille tuotteitaan. Myynnin menetystä voi tapahtua monesta syystä. Jos yrityksellä on liian vähän tavaraa varastossaan, se voi menettää monia mahdollisia asiakkaita, jos ne vaihtavat toimittajaa. Asiakkaita voidaan lisäksi menettää huonon kilpailukyvyyn, kuten korkean hinnan, huonon laadun tai mainehaitan takia. Tuotteista voi myös tulla myyntikelvottomia. Esimerkiksi elintarvikkeet voivat pilaantua nopeasti. Sen sijaan elektroniikka voi vanheta tai vaatteet voivat mennä pois muodista, jolloin niitä ei voi enää myydä, tai ne voidaan joutua myymään suurilla alennuksilla, joista syntyy tappiota. Puutekustannukset eivät varsinaisesti ole suoria kustannuksia eli niistä ei aiheudu rahavirtoja. Tehokkaammalla varastotasojen hallinnalla ja seurannalla on kuitenkin

mahdollista välttää edellä mainittuja tilanteita ja saada täten lisää myyntiä ja tuottoja. (Krajewski & Malhotara 2022.) Kustannussäästöjen lisäksi hävikin väheneminen tekee yritysten toiminnasta vastuullisempaa ja ympäristöystävällisempää.

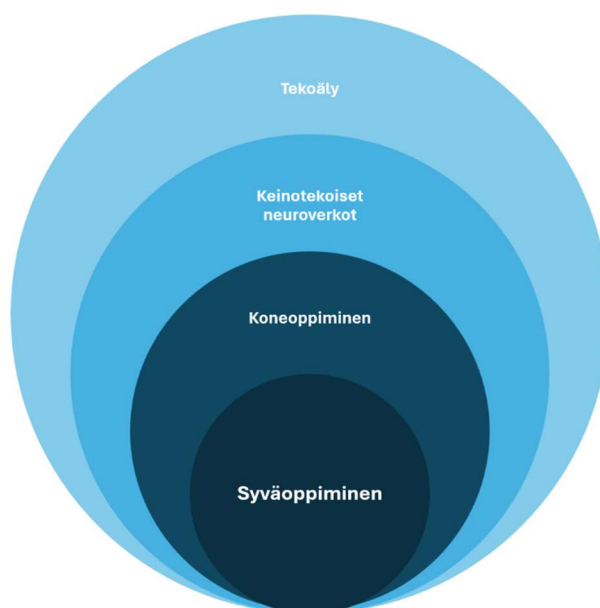
3 Tekoäly

Tässä luvussa käsitellään tekoälyn teoriaa sekä käsitteitä, ja tarkastellaan sen erilaisia ominaisuuksia ja toimintamalleja. Tekoälyä on vaikeaa määrittää yhdellä tietyllä tavalla, ja siitä käytetään usein erilaisia määritelmiä. Kirjassaan Sheikh ym. (2023) määrittelevät sen muun muassa teknologiana, jonka avulla koneet kykenevät matkimaan vaativia ihmisen taitoja. Ongelmana on kuitenkin se, että nuo kyseiset taidot ja ihmisen älykkyyys yleisesti ovat myös vaikeita määrittellä, mikä tekee tekoälynkin määrittelystä haastavaa. Esimerkiksi shakin pelaaminen on ihmiselle haastavaa, mutta koneelle helppoa. Toisaalta ihmisille erittäin helppo asia, kuten kissan tunnistaminen kuvasta voi tuottaa koneelle vaikeuksia. Toisessa määritelmässä he kuvaavat tekoälyä järjestelmänä, joka pystyy käyttäytymään älykkäästi analysoimalla ympäristöään ja tekemällä sen perusteella johtopäätöksiä.

Nyky maailman koneet ja järjestelmät ovat tehokkaita, ja ne pystyvät ratkaisemaan vaikeitakin ongelmia. Ongelmat täytyy kuitenkin määrittellä erittäin tarkasti, ja kaikille prosessin vaiheille täytyy luoda omat menetelmät ja kaavat, jotta ne saadaan ratkaistua. Tekoälyn merkittävin ominaisuus lieneekin siinä, että se kykenee käsittelemään suuria määriä dataa ja etsimään itsenäisesti oikeanlaiset työkalut ongelman ratkaisemiseksi. Lisäksi se tekoäly pystyy havaitsemaan datasta erilaisia syy-seuraussuhteita ja oppimaan niistä itsenäisesti lisää.

3.1 Tekoälyn tasot


Tekoäly voidaan jakaa erilaisiin alakäsitteisiin sekä -tasoihin hierarkkisesti sen perusteella, kuinka syvällistä ja laaja-alaista datan käsittely on. Kreutzer ja Sirrenberg (2020) jakavat tekoälyn kirjassaan neuroverkkoihin (engl. neuronal network), koneoppimiseen (engl. machine learning) ja syväoppimiseen (engl. deep learning). Kuvio 4 havainnollistaa tekoälyn eri tasoja.



Kuvio 4. Tekoälyn tasot (mukaien Kreutzer & Sirrenberg 2020)

3.1.1 Neuroverkot

Keinotekoiset neuroverkot muodostuvat erilaisista kerroksista, joiden avulla pystytään käsittelemään dataa ja ratkaisemaan ongelmia. Eri kerrokset ovat vuorovaikutuksessa keskenään kuvion 5 mukaisesti. (Kreutzer & Sirrenberg 2020.) Neuroverkko koostuu solmukohtista, jotka jäljittelevät biologisesti ihmisen aivojen hermosoluja, ja niitä kutsutaankin keinotekoisiksi hermosoluiksi (Krenker ym. 2011).



Kuvio 5. Neuroverkot (mukaien Kreutzer & Sirrenberg 2020)

Neuroverkon toiminta perustuu eri kerrosten keskinäiseen vuorovaikutukseen. Ongelmanratkaisuprosessi alkaa siten, että ensimmäinen kerros eli syötekerros (engl. input-layer) vastaanottaa dataa, jota se alkaa käsittelemään kerros kerrokselta. Lopuksi ongelma etenee viimeiseen eli ulostulokerrokseen (engl. output-layer), josta se antaa ongelmaan ratkaisun. Syöte- ja ulostulokerroksen välissä ovat piilokerroksia (engl. hidden-layer), joissa itse ongelmanratkaisu tapahtuu. Mitä enemmän piilokerroksia on, sitä monimutkaisempia ongelmia neuroverkon avulla voidaan tutkia ja sitä tarkempia tuloksia voidaan saada. Eri kerrokset ja keinotekoiset hermosolut muodostavat matemaattisen mallin, ja ne toimivat käytännössä funktion lailla. Sille pitää siis luoda toimintatavat ja algoritmit, joiden mukaan se toimii, ja joiden avulla syötetystä datasta saadaan vastauksia. (Kreutzer & Sirrenberg 2020.) Tapaa millä keinotekoiset hermosolut ovat yhdistyneitä toisiinsa kutsutaan topologiaksi, ja se määrittää minikälaisia ongelmia voidaan ratkaista (Krenker ym. 2011). Neuroverkkoja voidaan siis järjestellä todella monilla eri tavoilla, eli on mahdollista luoda monenlaisia topologioita. Voidaan esimerkiksi määrittää, liikkuuko informaatio kerrosten välillä suoraviivaisesti vai edestakaisin.

3.1.2 Koneoppiminen

Koneoppimisella tarkoitetaan jonkin koneen kykyä oppia itsenäisesti uusia taitoja. Perinteiselle koneelle on tyypillistä käyttää sääntöihin ja ennalta määrättyihin algoritmeihin perustuvaa järjestelmää eli käytännössä ne ratkaisevat ongelmia aina samalla tavalla. Koneoppimista hyödyntävälle koneelle niin ikään annetaan sääntöjä ja algoritmeja, mutta perinteisen koneen sijaan se pyrkii itse kehittämään alkuperäisistä algoritmeista tehokkaampia ja lisäksi luomaan kokonaan uusia algoritmeja (Kreutzer & Sirrenberg 2020).

Koneoppiminen perustuu siihen, että se käsittelee suuria määriä dataa, ja ihmisaivojen tapaan pyrkii oppimaan sen pohjalta uutta. Koneoppimista hyödyntävää konetta tai prosessia on mahdollista kouluttaa tehokkaammaksi syöttämällä sille koulutusdataa ja pyytämällä sitä käsittelemään sitä eri tavoilla. Kouluttamista voidaan tehdä eri tavoilla ja ne on jaettu usein kolmeen eri tapaan: valvottu oppiminen (engl. supervised learning), valvottoman oppiminen (engl. unsupervised learning) ja vahvistusoppiminen (engl. reinforcement learning). (Kreutzer & Sirrenberg 2020.)

Valvotussa oppimisessa tekoälylle annetaan ongelma ja lisäksi siihen vastaus. Tarkoituksena on, että tekoäly tarkastelee yhteyksiä ongelmien ja ratkaisujen välillä ja pyrkii näin kehittämään oikeanlaisia algoritmeja. Kun sopiva algoritmi on löytynyt, sitä voidaan alkaa käyttämään uutta dataa käsiteltäessä. Valvottua oppimista voisi hyödyntää esimerkiksi autojen hintojen määrittämisessä. (Kreutzer & Sirrenberg 2020.) Tekoälylle voitaisiin antaa dataa autoista, niiden osista sekä ominaisuuksista ja

hinnoista. Tämän jälkeen tekoäly selvittää kuinka erilaiset tekijät vaikuttavat auton hintaan. Tekoäly kehittää algoritmin, jonka avulla se voi myöhemmin selvittää minkä tahansa auton hinnan.

Valvomattomassa oppimisessa tekoälylle ei anneta ongelmaan vastauksia tai menetelmiä sen ratkaisemiseksi. Sen pitää siis itsenäisesti löytää oikeanlaisia yhteyksiä annetusta datasta. Yhtenä yleisenä menetelmänä tekoäly käyttää klusterointia. (Krenker ym. 2011.) Siinä se pyrkii erittelemään dataa erilaisiin kategorioihin eli klustereihin ja yrittää sitä kautta löytää yhtäläisyyksiä.

Vahvistusoppimisessa on ominaisuuksia sekä valvotusta, että valvomattomasta oppimisesta. Siinä tekoäly kokeilee erilaisia menetelmiä ja pyrkii iteroimalla löytämään niistä oikean. Tekoälylle ei anneta ongelmaan täysin oikeita ratkaisuja, mutta sille kerrotaan, oliko käytetty menetelmä oikea vai väärä, eli johtiko se lähemmäs ratkaisua. (Du ym. 2025.) Järjestelmä palkitsee tekoälyä oikeista menetelmistä ja rankaisee vääristä. Mitä pidempään tekoäly tekee iterointiprosessia, sitä parempia tuloksia se saa. Välillä vahvistusoppiminen saattaa kuitenkin olla hieman hitaampi menetelmä, jos dataa on paljon ja iterointi on työläämpää.

3.1.3 Syväoppiminen

Syväoppiminen on yksi koneoppimisen alakäsitteistä, ja se toimii sen kanssa osittain samojen tapojen mukaan. Se kuitenkin kykenee käsittelemään huomattavasti enemmän dataa ja se vaatii paljon vähemmän ennalta määriteltyjä sääntöjä kuin koneoppimista hyödyntävä prosessi. Syväoppiminen käyttää hyväkseen keinotekoisia neuroverkkoja, ja se pyrkii jäljittelemään mahdollisimman tarkasti ihmisaivojen toimintaa. (Taye 2023.) Jos neuroverkossa on enemmän kuin kaksi piilokerrosta, se hyödyntää syväoppimista ja sen sanotaan olevan syvä neuroverkko. Usein syväoppimismallien neuroverkoissa on kuitenkin erittäin monia kerroksia.

Syväoppimisessa neuroverkot käyttävät niin kutsuttuja aktivointifunktioita. Niiden avulla data liikkuu neuroverkon kerrosten välillä. Keinotekoisille hermosoluille määritellään funktiot, joilla ne käsittelevät niille tulevaa dataa. Lisäksi datan kaikille eri syötteille määritellään painokertoimet niiden merkittävyyden perusteella. Keinotekoiset hermosolut laskevat sitten funktioiden avulla painotetut summat ja aktivoivat seuraavan kerroksen lähettämällä syötteet sinne eteenpäin. Tämä prosessi toistuu niin kauan, kunnes data on liikkunut ulostulokerrokseen asti, missä sille määritellään ratkaisu.

Tayen (2023) mukaan syväoppiminen on tekoälyn tehokkain osa-alue itsenäisen oppimisen näkökulmasta. Se vaatii enemmän dataa toimiakseen paremmin kuin koneoppimisen järjestelmät, mutta se pystyy käsittelemään huomattavasti suurempia määriä dataa niihin verrattuna. Mitä enemmän dataa on, sitä paremmin syväoppimismallien algoritmit toimivat. Tehokkaan ja itsenäisen datan käsittelyn

ansioista syväoppiminen vaatii huomattavasti vähemmän ihmisen ohjausta sekä avustusta koneoppimiseen verrattuna, ja sen on myös mahdollista oppia omista virheistään.

Suurien datamäärien käsittelemiseksi syväoppimisessa hyödynnetään usein toistuvia neuroverkkoja (engl. RNN, Recurrent Neural Networks). Tämän tyyppiset neuroverkot kykenevät löytämään suurista datamääristä yhtäläisyyksiä, mutta sille koituu usein haasteita, jos data jakautuu pitkille ajanjaksoille. (Krichen & Mihoub 2025.) Tekoäly saattaa välillä unohtaa sellaista dataa, joka on vanhaa ja jota ei ole hyödynnetty hetkeen. Tämän ongelman ratkaisemiseksi toistuvat neuroverkot käyttävät niin kutsuttua pitkän lyhytaikaismuistin verkkoa (engl. LSTM, Long Short-Term Memory). LSTM toimii nimensä mukaisesti siten, että se yhdistelee sekä lyhytaikaisen että pitkäaikaisen muistin ominaisuuksia. Ensin se siis tarkastelee erikseen monien lyhyen aikavälin tapahtumien välisiä yhteyksiä, jonka jälkeen se pyrkii hahmottamaan laajempia yhteyksiä sekä kokonaisuuksia pidemmiltä ajanjaksoilta.

LSTM-prosessi perustuu muidenkin syväoppimismallien tapaan informaatiovirtojen hallintaan neuroverkossa. Se kuitenkin käyttää erilaisia portteja, joiden avulla päätetään mitä informaatiota käsitellään ja miten se liikkuu verkossa. Syöttöportti (engl. input gate) määrittelee sen, kuinka paljon uutta informaatiota LSTM-malliin otetaan mukaan. Ulostuloportti (engl. output gate) taas määrittelee sen, mitkä informaation osat saaduista tuloksista otetaan mukaan seuraavaan LSTM:n vaiheeseen. Kolmannessa, unohdusportissa (engl. forget gate) LSTM-malli päättää, mikä informaatio on epäolennaista tai virheellistä, ja poistaa kyseisen informaation järjestelmästä. Van Houdt ym. (2020) kuvailevat tutkimuksessaan LSTM-mallin koostuvan erilaisista muistilohkoista (engl. memory blocks), jotka pitävät yllä neuroverkkoon kuuluvaa informaatiota ja päivittävät sitä jatkuvasti.

LSTM-mallia käytetään tyypillisesti erilaisissa ennustemalleissa. Niillä voidaan ennustaa esimerkiksi rahoitusmarkkinoita tai jonkin tuotteen kysyntää. Sagheer ja Kotb (2019) hyödynsivät öljyn tuotannon ennustamiseen liittyvässä tutkimuksessaan syväoppimista siten, että he asettivat monia LSTM-malleja toistensa päälle kerroksittain. Jokainen kerros käsiteli tietylle ajanjaksolle kuuluvaa dataa, ja kun data liikkui kerrosten välillä, löydettiin niiden välisiä yhtäläisyyksiä ja pystyttiin muodostamaan parempi kokonaiskuva kysynnästä.

4 Tekoälyn hyödyntäminen varaston optimoinnissa

Aiemmissa luvuissa on erikseen määritelty varaston optimoinnin ja tekoälyn käsitteitä, ja käsitelty niiden yleisiä teorioita sekä käytäntöjä. Tämän luvun tarkoituksena on havainnollistaa niiden välistä yhteyttä eli tarkastella kuinka tekoälyä voidaan konkreettisesti hyödyntää varaston optimoinnissa. Lisäksi käsitellään haasteita, joita voi ilmetä tekoälyä käytettäessä.

Tekoälyn käytöllä pyritään yleensä tehostamaan perinteisten varaston optimoinnin menetelmien suoriutumista. Suoriutumista on jo kyetty tehostamaan automaation avulla, mutta tekoälyn avulla sitä on mahdollista kehittää vielä huomattavasti paremmiksi. (Bhavikatta 2025.) Lisäksi tekoälyllä voidaan luoda myös täysin uudenlaisia menetelmiä varaston optimointiin. Tekoäly voi muun muassa ennustaa kysyntää tarkemmin, se voi jatkuvasti kehittää itsenäisesti omia prosessejaan ja tehdä varaston operatiivisesta toiminnasta selkeämpää sekä sujuvampaa.

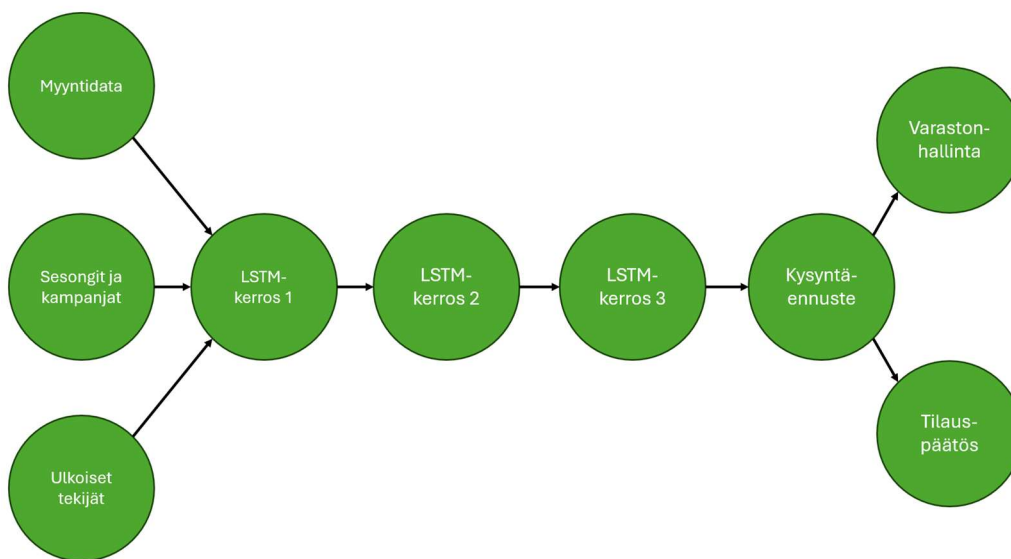
Perinteiset varastoinnin menetelmät antavat kattavan teoreettisen kehyksen varaston optimointiin. Ne ovat kuitenkin nykypäivän monimutkaisiin ja jatkuvasti muuttuviin toimitusketjuihin aivan liian suppeita. Kaupankäynnin volyymit ovat niin suuria ja tahti on niin nopeaa, että kysynnässä tapahtuu koko ajan suuria, usein odottamattomia muutoksia. Tieto liikkuu niin nopeasti, että uutiset ja uudet trendit ehtivät vaikuttaa kysyntään jo ennen kuin ihmiset huomaavat niitä. Perinteisissä menetelmissä ei usein edes oteta huomioon toimitusketjussa tapahtuvaa vaihtelua, ja monen tekijän oletetaan pysyvän muuttumattomana, esimerkiksi kysynnän ja toimitusaikojen. Nämä tekijät määritellään yleensä historiallisen datan perusteella. Lisäksi perinteiset menetelmät vaativat paljon manuaalista työtä, kuten optimaalisten tilausmäärien analysointia, tilauksien tekemistä ja tavaroiden käsittelyä varastossa. Työ vie tekoälyä hyödyntäviin tapoihin verrattuna enemmän aikaa ja aiheuttaa enemmän kustannuksia.

4.1 Kysynnän ennustaminen

Yksi keskeisimmistä varastotasojen optimoinnin haasteista on kysynnän ennustaminen. Ennustamista varten on perinteisesti luotu malleja, jotka perustuvat historiallisen datan analysointiin. Niiden avulla voidaan esimerkiksi analysoida sitä, mihin aikaan vuodesta, viikosta tai vaikkapa päivästä kysyntä on normaalia suurempaa, ja milloin toisaalta pienempää. Laadukasta tiedonlouhintaa (engl. data mining) hyödyntämällä on mahdollista kerätä paljon dataa ja saada pitkältikin ajalta tietoa kysynnästä sekä sen vaihtelusta. Tekoälypohjaisten mallien avulla on sen sijaan mahdollista löytää kysyntään liittyvä syy-seuraussuhteita ja selvittää, mitkä tekijät vaikuttavat sen äkillisiin muutoksiin.

Tutkimuksessaan Deng ja Liu (2021) selvittivät, että tekoälyä hyödyntävällä kysynnän ennustamis- mallilla ennustamisen tarkkuus voi olla yli 80 %. Mallin avulla myös varastointikustannuksia on mahdollista vähentää noin 25 %:lla. Kysynnän ennustamisen parantamiseksi tutkimuksessa varaston optimoinnin järjestelmään luotiin keinotekoinen neuroverkko, joka hyödyntää kone- ja syväoppi- mista. Tarkimman tuloksen saamiseksi yhdisteltiin LSTM-mallia ja aikasarja-analyysiä. Tällaisesta mallista käytetään usein nimitystä ”Deep Inventory Management” (DIM). Perinteisessä aikasarja- analyysissä kerätään dataa pitkältä aikaväliltä, jotta voidaan löytää yhteyksiä ja trendejä tapahtumien välillä (Krichen & Mihoub 2025). LSTM-mallilla voidaan siis tehostaa aikasarja-analyysiä, kun dataa pystytään käsittelemään huomattavasti enemmän.

Perinteisen kysynnän ennustamisen mallien käyttämä data perustuu pitkälti aiempien vuosien kysyn- nän dataan. Tällainen data on strukturoitua eli sitä on helppo käsitellä ja analysoida. Toisaalta siitä ei saa kovin tarkkoja tuloksia tai hyödyllisiä havaintoja, joiden avulla ennustamisen tarkkuutta voitaisiin parantaa. LSTM-mallit sen sijaan pystyvät käsittelemään strukturoidun datan lisäksi myös epästruk- turoitua dataa (Bhavikatta 2025). Kuvio 6 kuvastaa kuinka LSTM-pohjaista tekoälymallia voidaan hyödyntää varaston optimoinnissa.



Kuvio 6. Tekoälyn hyödyntäminen varaston optimoinnissa LSTM-mallin avulla (mukaan Ma ym. 2024)

Ma ym. (2024) kehittivät tutkimuksessaan kuvion 6 mukaisen LSTM-mallin, joka tunnistaa normaalia poikkeavia ajanjaksoja sekä tapahtumia, ja pystyy ottamaan myös ne huomioon kysynnän ennustamisessa ja tilauspäätöksissä. Se voi aiemman myyntidatan lisäksi huomata esimerkiksi ajanjaksoja, jolloin jollakin tietyllä toimialalla menee normaalia paremmin tai huonommin, ja kysynnässä saattaa olla yllättäviä muutoksia. Tällaiset tilanteet voivat esimerkiksi aiheutua yritysten tekemien

mainos- ja tarjouskampanjoiden myötä. Lisäksi täysin ulkoiset tekijät, kuten ajankohtaiset uutiset, sosiaalisen median trendit tai sääolosuhteiden vaikutus kuljetusten aikatauluihin pystyttäisiin ottamaan huomioon. Jos esimerkiksi johonkin tuotteeseen tarvittavan raaka-aineen hinta nousisi yllättäen, jolloin se nostaisi myös kyseisen tuotteen hintaa, tekoälyn avulla tämän voisi ennustaa uutisvirrasta ja markkinatrendien muutoksesta. Tällöin tilausmäärät sekä varastotasot olisi mahdollista mukauttaa muuttuneeseen kysyntään.

Syväoppimismallit keräävät datasta koko ajan ajankohtaista tietoa, ja ne pystyvät ottamaan sitä reaaliaikaisesti mukaan tarkasteluun uusien johtopäätösten tekemiseksi. Ne pystyvät esimerkiksi muuttamaan tilausmääriä, jos kysynnässä tapahtuu yllättävä muutos, vaikka aikaisemman datan pohjalta olisi jo tehty tilauspäätös. Myös yrityksen omassa toimitusketjussa tapahtuviin muutoksiin pystytään reagoimaan nopeasti ja tehokkaasti. Toimittajia voidaan muun muassa seurata koko ajan, ja niiden toiminnassa tapahtuvat häiriöt voidaan huomata ajoissa ja vaikutukset omaan toimintaan pystytään ennakoimaan. (Bhavikatta 2025.) Asiakaspalautteet ja -toiveet pystytään myös huomioimaan kysynnän ennustamisessa tekoälyn avulla. Suurien datamäärien käsitteleminen vaatii tasokkaita ja erittäin suuria tietokantoja. Esimerkiksi yhdysvaltalainen vähittäiskauppa Walmart käsittelee joka tunti miljoonia transaktioita, jotka voivat lisätä sen tietokantoihin jopa 2,5 petatavua. (Ma ym. 2024.)

Ma ym. (2024) havaitsivat empiirisessä case-tutkimuksessaan, että tekoälyllä on huomattavia vaikutuksia varaston optimointiin ja kysynnän ennustamiseen. Tutkimuksessa tarkkailtiin biologisia lääkkeitä myyvää yritystä. Tutkimusta toteutettiin sekä kvalitatiivisilla että kvantitatiivisilla menetelmillä, ja dataa kerättiin 18 kuukauden ajalta, esimerkiksi yrityksen tietojärjestelmistä, haastatteluista sekä asiakaskyselyistä. Taulukko 1 havainnollistaa tekoälyn käytön tuomia parannuksia.

Taulukko 1. Tekoälyn käytön hyödyt (mukaien Ma ym. 2024)

Mittari	Ennen tekoälyn käyttöä	Tekoälyn käytön jälkeen	Parannus
Varaston kiertonopeus	4,2	5,8	38,1 %
Varaston loppuminen	3,5 %	0,8 %	77,1 %
Toimitusten täsmällisyys	88 %	96 %	9,1 %
Asiakaspysyvyys	82 %	91 %	11,0 %
Liikevoitto	72 milj. \$	94,5 milj. \$	31,3 %
Varastointikustannukset	18 milj. \$	14,5 milj. \$	19,4 %

Tekoälyn avulla pystyttiin parantamaan muun muassa toimitusketjun tehokkuutta ja varaston operatiivista toimintaa. Varaston kierto nopeutui, puutetilanteet, jossa varasto loppui kokonaan, vähenivät ja toimitukset saapuivat paikalle täsmällisemmin. Näin vältettiin paremmin tilanteita, joissa syntyy yli- ja alivarastoja. Lisäksi asiakastyytyväisyys parani. Asiakkaat olivat tyytyväisempiä ja he todennäköisemmin ostivat uudestaan ja suosittelivat tuotteita muillekin. Myös taloudellisissa mittareissa tapahtui kehitystä. Sekä liikevaihto että -voitto kasvoivat, tuotekohtainen kannattavuus parani ja varastointikustannuksissa tehtiin säästöjä.

Kuten edellä mainittiin, perinteiset varastoinnin menetelmät ovat puutteellisia suurien volyymien kaupankäynnissä. Tekoälypohjaisilla malleilla kysynnän ennustaminen on kuitenkin huomattavasti tarkempaa. Aiheeseen liittyvän kirjallisuuden perusteella voidaankin tehdä johtopäätös, että tekoälypohjaisia malleja voisi hyödyntää perinteisissä menetelmissä. Esimerkiksi EOQ-mallia voi olla erittäin tehokasta hyödyntää, jos aiemmin vakiona oletettu kysyntä pystytään ennustamaan tekoälyn avulla tarkemmin. Myös ROP-mallia voidaan hyödyntää paremman ennustustarkkuuden myötä, ja eri tuotteille pystytään paremmin määrittämään, onko esimerkiksi järkevämpää käyttää jatkuvan menetelmän seurantaa vai periodiseurantaa. Tehokkaan ROP:n määrittämisen myötä voisi olla myös mahdollista päästä lähemmäksi JIT-menetelmän käyttöä, jolloin uusi täydennystilaus saataisiin juuri vanhan erän loppuessa. Tekoäly ei kuitenkaan kykene täydelliseen tarkkuuteen ja epävarmuuksia ilmenee silti. Varmuusvarastoa täytyy siis silti pitää yllä, mutta sitä ei välttämättä tarvita niin paljon.

4.2 Älykkäät täydennystilaukset

Älykkäät täydennystilaukset tarkoittavat sitä, ettei ihmisten tarvitsisi tehdä täydennystilauksia vaan ne voitaisiin jättää tekoälylle. Järjestelmiin voidaan rakentaa tekoälyagentteja, jotka tekevät itsenäisiä tilauspäätöksiä. Päätöksiä tehdään simuloimalla ja vertailemalla keskenään lukuisia eri skenaarioita sekä strategioita. Vahvistusoppimisen avulla tekoälyagentit saavat jatkuvasti palautetta tekemistään päätöksistä, ja ne voivat täten tunnistaa virheellisiä päätöksiä ja muuttaa toimintaansa välttääkseen virheet tulevaisuudessa. Lisäksi manuaalisesta työstä aiheutuvat huolimattomuusvirheet vähenevät huomattavasti vahvistusoppimisen tuoman automaation myötä. Abu Zwaidan ym. (2021) tutkimuksessa liittyen sairaaloiden lääketilauksiin hyödynnettiin vahvistusoppimista. Tutkimuksessa havaittiin, että vahvistusoppimisen ansiosta puutetilanteiden määrä väheni ja operatiivisia kustannuksia pystyttiin vähentämään. Päätöksiä tehdessään tekoälyagentit analysoivat jatkuvasti reaaliaikaista dataa ja tekevät sen pohjalta dynaamisesti arvioita varmuusvaraston tarpeista (Bhavikatta 2025).

4.3 Varaston operatiivisen toiminnan kehittäminen

Varastotasojen ja täydennysmenetelmien optimoinnin lisäksi tekoälyllä voidaan optimoida myös varaston operatiivista toimintaa eli toimintaa, joka tapahtuu fyysisen varaston sisällä. Se voi olla muun muassa varaston ”layoutin” eli pohjapiirustuksen suunnittelua, tuotteiden sijoittamista varastoon, tuotteiden keräilyä sekä keräilyjärjestyksen optimointia ja tuotteiden tunnistamista. Näitä toimintoja kehittämällä varaston toiminnasta tulee nopeampaa sekä tehokkaampaa ja kustannuksia voidaan alen-
taa.

Tekoälyllä voidaan nopeuttaa tavaroiden paikantamista varastossa. Varastossa liikkuviin robotteihin voidaan asentaa kameroita, jotka hyödyntävät konenäköä (engl. computer vision). Kyseiset robotit kykenevät tunnistamaan esineitä kuvista tai videoista, ja niiden avulla tavaroita voidaan paikantaa sekä tunnistaa tehokkaammin. Kameroiden avulla voidaan tarkistaa varastotasoja eli inventaarioita voidaan suorittaa huomattavasti nopeammin. Tadjine ym. (2025) kertovat tutkimuksesta, missä viljavarastoon kehitettiin järjestelmä, jonka avulla viljan määrää pystyttiin tarkkailemaan automaattisesti. Järjestelmässä käytettiin infrapunasäteilyllä toimivaa etäisyysmittaria, joka laski viljan tilavuutta. Lisäksi konenäöllä voidaan tunnistaa virheellisiä tuotteita. Kun järjestelmälle syötetään tarpeeksi dataa tuotteista, se pystyy syväoppimisen avulla tunnistamaan, mikäli tuote on virheellinen, esimerkiksi pilaantunut. Li ym. (2025) kertoivat menetelmästä, jossa tekoälyn avulla hedelmien tuoreutta varastossa pystyttiin tunnistamaan 99,78 %:n tarkkuudella. Myös turvallisuutta pystytään parantamaan konenäön avulla. Kameran pystyvät tarkkailemaan varaston sisällä tapahtuvaa toimintaa ja antaa ennalta ehkäiseviä varoituksia, jos se huomaa vaarallista toimintaa, esimerkiksi koneiden tai ihmisten liikkeistä.

Konenäöllisiä kameroita voidaan asentaa myös lentäviin ja itseohjautuviin drooneihin, joiden toiminta perustuu 3D-paikannukseen (Al-hamadani & Al-Darraji 2025). Droonit pystyvät liikkumaan paljon nopeammin, ja ne pääsevät sellaisiin paikkoihin, mihin ihmiset tai muut maassa liikkuvat robotit eivät välttämättä pääse. Sen ansiosta droonit voivat tunnistaa varaston hyllyissä, koneissa tai muissa osissa ilmeneviä vikoja tai puutteita ja ennakoida niille tarvittavia huoltoja. Myös varaston olosuhteita, kuten lämpötilaa ja kosteutta on tehokasta tarkkailla drooneilla, jotka pääsevät liikkumaan vapaammin. Laajan sekä tarkan visuaalisen datan avulla droonit pystyvät tekemään myös havaintoja ja päätöksiä täydennystilauksista. Konenäön lisäksi droonit voivat itsenäisesti liikuttaa tavaroita, ja niitä voidaan käyttää myös kuljetuksiin varaston sisällä.

Kun tavaraa saapuu varastoon, se pitää ottaa vastaan ja hyllyttää. Usein varastot ovat isoja ja varastopaikkoja voi olla tuhansia. Hyvin suunnitellulla tuotteiden sijoittelulla on mahdollista tehdä

varaston toiminnasta tehokkaampaa. Tuotteiden keräily on paljon nopeampaa, jos oikeat tavarat sijaitsevat varastossa oikeilla paikoilla ja keräilyyn käytettävä aika ja etäisyydet ovat mahdollisimman pieniä. On arvioitu, että tuotteiden keräily hyllyistä aiheuttaa noin 55-65 % kaikista varaston kustannuksista, joten niiden optimaalinen sijoittelu on myös sen kannalta merkittävä tekijä (Zöls ym. 2024).

Tuotteiden sijoittamista varastoon voidaan optimoida mukaillen luvussa 2.1.4 käsiteltyä ABC-analyysiä. Tässä menetelmässä tuotteet luokitellaan eri kategorioihin tuottavuuden ja volyymien sijaan niiden kiertonopeuden perusteella, eli sen perusteella kuinka kauan ne todennäköisesti viettävät aikaa varastossa. Katgoriaan A kuuluvat sellaiset tuotteet, joiden kiertonopeus on korkea, ja katgoriaan C sen sijaan kuuluvat sellaiset tuotteet, joiden kiertonopeus on alhainen. Mitä korkeampi kiertonopeus tuotteella on, sitä lähemmäs keräilypistettä ne kannattaa sijoittaa, jotta keräilyihin käytettävä matka olisi mahdollisimman lyhyt.

Varaston ”layout” voidaan rakentaa tehokkaasti. Tekoölyn avulla varaston hyllyt voidaan asetella niin, että etäisyydet olisivat mahdollisimman lyhyet ja että keräily tapahtuisi nopeasti. Aikaa ja etäisyyksiä voidaan pienentää myös sijoittamalla tuotteet paremmille paikoille varastossa. Zöls ym. (2024) kehittivät tutkimuksessaan tekoölypohjaisen, ABC-analyysiä tehokkaamman algoritmin, jonka avulla tuotteiden sijoittelua varastossa voidaan optimoida. Siinä varasto jaetaan eri alueisiin eli niin sanottuihin klustereihin. Algoritmi käyttää kaksivaiheista päätöksentekomenetelmää, jossa tavarann saapuessa varastoon tekoöly päättää ensin mihin klusteriin se ohjataan, ja sen jälkeen se päättää mille hyllypaikalle kyseisessä klusterissa se hyllytetään. Menetelmä perustuu keräilyetäisyyksien ja tuotteiden kiertonopeuden analysointiin. Järjestelmään määritetään kaikkien varastopaikkojen väliset etäisyydet, ja tekoölyn avulla määritellään todennäköisyyksiä sille, kuinka nopeasti tuote tulee poistumaan varastosta. Näiden tietojen perusteella tekoöly määrittelee mille varastopaikalle tuote olisi kaikkein optimaalisinta sijoittaa.

Kun ”layout” on päätetty tai kun sitä on muutettu, varastossa liikkuvat robotit voidaan tekoölyn avulla optimoida siten, että ne osaavat mukautua siihen. Tällöin ne osaavat tehdä päätöksiä liittyen keräilyjärjestykseen ja tuotteiden sijoitteluun. Varaston ”layoutia”, tuotteiden sijoittelua ja keräilyä sekä hyllylytystä voidaan optimoida ilmankin tekoölyä, mutta tekoölyn kyky käsitellä nopeasti suuria määriä dataa kuitenkin tehostaa varaston operatiivista toimintaa huomattavasti. Li ym. (2025) havaitsivat robottien optimoinnin lisäävän käsiteltävien tilausten määrää 17–23 %:lla, ja tilausten käsittelyyn käytettävää aikaa pystyttiin vähentämään 30 %:lla.

4.4 Tekoälyn haasteet varaston optimoinnissa

Tekoälyn hyödyntäminen varaston optimoinnissa tuo yrityksille monia etuja ja usein se sujuvoittaa niiden toimintaa. Monille yrityksille tekoälyn käyttö tai sen käyttöönotto voi kuitenkin aiheuttaa haasteita. Haasteet liittyvät usein kustannuksiin, osaamattomuuteen, datan laatuun, tietoturvallisuuteen tai ihmisten yleisiin näkemyksiin tekoälystä.

Vaikka pitkällä aikavälillä tekoäly lisää tehokkuutta ja voi pienentää kustannuksia, sen käyttöönotto on kuitenkin usein kallista ja se vaatii suuria investointeja. Tämä on haaste erityisesti pienille ja keskisuurille yrityksille, joilla ei yleisesti ole resursseja suurten investointien tekemiseen. Käyttöönottoa varten täytyy yleensä palkata uusia työntekijöitä ja asiantuntijoita. Yrityksellä tulee olla kyky tehokkaaseen muutosjohtamiseen, sillä muutokset ovat suuria ja uutta opittavaa on paljon. (Bhavikatta 2025.)

Tekoäly vaatii huomattavasti enemmän dataa toimiakseen tehokkaasti verrattuna perinteisiin datankäsittelykeinoihin. Tämän lisäksi datan tulee olla laadukasta. Sen tulee olla ajankohtaista, relevanttia ja yksityiskohtaista. Mitä enemmän dataa on saatavilla ja mitä laadukkaampaa se on, sitä parempia sekä tarkempia tuloksia saadaan ja sitä enemmän tekoäly pystyy kehittämään omaa toimintaansa. Suomen Osto- ja Logistiikkayhdistyksen *Osto&Logistiikka* -lehdessä Nortio (2026) kertoo yhdestä yrityksestä, jossa juuri datan laatu ja saatavuus oli yksi suurimmista haasteista tekoälyä hyödyntäessä. Yhtenä haasteena voi olla myös yrityksen ulkopuolisen datan, kuten toimittajien, asiakkaiden tai muiden sidosryhmien datan integroiminen omiin järjestelmiin (Hangl ym. 2023). Jos yrityksellä on esimerkiksi dataa yhdestä tilanteesta, joka on vaikuttanut kysyntään ja tilausmääriin, vaikka jonkin toimittajan konkurssin takia, tekoäly tekee seuraavassa samankaltaisessa tilanteessa johtopäätöksen todennäköisesti sen pohjalta. Jos dataa on sen sijaan monista samanlaisista tapahtumista, tekoäly pystyy vertailemaan niitä keskenään ja saamaan aikaan tarkempia tuloksia. Se pystyy helpommin löytämään ongelmalle sen todellisia syitä eli juurisyitä. Suurien datamäärien käsittely vaatii yrityksiltä uusien ohjelmistojen ja järjestelmien hankkimista (Bhavikatta 2025). Myös nykyisiä ohjelmistoja täytyy päivittää, ja yleisesti yrityksen datainfrastruktuuria tulee kehittää, jotta kaikki uusi data saadaan integroitua järjestelmiin.

Tekoäly saattaa myös aiheuttaa muutosvastarintaa nykyisten työntekijöiden keskuudessa. He eivät välttämättä ymmärrä tekoälyn hyödyllisiä puolia ja saattavat kokea sen käyttöönoton turhanpäiväisenä. Tekoäly pystyy korvaamaan monia työtehtäviä, joten työntekijät saattavat olla myös huolissaan omista työpaikoistaan. Hanglin ym. (2023) tutkimuksessa todettiin, että kulttuurisilla eroilla on myös vaikutusta siihen, miten ihmiset suhtautuvat tekoälyyn. Esimerkiksi Aasiassa ihmiset suhtautuvat

myönteisemmin tekoälyn tuomiin uudistuksiin kuin Euroopassa. Eurooppalaiset ovat huolissaan muun muassa tietoturvallisuuden liittyvistä asioista, kuten tekoälyn vaikutuksista EU:n yleiseen tietosuoja-asetukseen GDPR:ään. Amerikkalaiseen kulttuuriin kuuluu myönteisempi suhtautuminen riskien ottamiseen ja virheiden tekemiseen, joten tekoäly nähdään siellä enemmän mahdollisuutena kuin uhkana.

5 Yhteenveto ja johtopäätökset

Tässä tutkielmassa tarkasteltiin erilaisia tapoja, joilla tekoälyä voidaan hyödyntää varaston optimoinnissa. Tavoitteena oli löytää keinoja, joiden avulla perinteisten varaston optimoinnin menetelmien suoriutumista voitaisiin tehostaa, ja lisäksi aivan uusia varaston optimoinnin keinoja, joita tekoäly mahdollistaa.

Tutkielmassa pyrittiin vastaamaan seuraaviin tutkimuskysymyksiin:

- Miten varastoinnin ja varaston optimoinnin perinteisten menetelmien suoriutumista voidaan kehittää tekoälyn avulla?
- Mitä uusia keinoja sekä teknologioita tekoäly tuo varastointiin ja varaston optimointiin?

Tutkielman perusteella voidaan todeta, että tekoälyä voidaan hyödyntää varaston optimoinnissa monilla eri keinoilla. Merkittävimmät hyödyt liittyvät kysynnän ennustamisessa tehtäviin parannuksiin. Syväoppimismallien ja keinotekoisien neuroverkkojen avulla dataa pystytään keräämään sekä käsittelemään huomattavasti enemmän, eikä sen tarvitse olla strukturoitua, jolloin dataa voidaan kerätä myös paljon muualta kuin vain aiemmasta myyntidatasta, esimerkiksi uutisista. Kun kysyntää pystytään ennustamaan tarkemmin, varaston optimoinnin perinteisten menetelmien suoriutumista voidaan tehostaa. Tiluserien koko pystytään määrittämään optimaalisemmin ja täydennystilauksia voidaan tehdä täsmällisempään aikaan. Tällöin esimerkiksi EOQ- ja ROP-malleja on huomattavasti järkevämpää hyödyntää. Tekoälyn avulla myös varmuusvarastojen tarve pystytään ennakoimaan paremmin. Monien varastojen toimintaa on jo automatisoitu paljon, mutta tekoälyn avulla automatisointia voidaan tehostaa entisestään. Tekoäly voi muun muassa itsenäisesti tehdä päätöksiä täydennystilauksista.

Perinteisten mallien suoriutumisen tehostamisen lisäksi tekoäly mahdollistaa myös aivan uudenlaisien työkalujen sekä keinojen käytön varaston optimoinnissa. Nämä keinot liittyvät pitkälti varaston operatiivisen toiminnan kehittämiseen. Varastossa voidaan käyttää älykkäitä robotteja ja drooneja, jotka osaavat tehdä itse keräilyä ja pystyvät optimoimaan siihen käytettävää aikaa. Varaston layout voidaan myös optimoida, jolloin keräilyetäisyyksiä voidaan lyhentää ja tuotteita voidaan sijoittaa älykkäämmin.

Kuten tutkielman alussa mainittiin, varastonhallinta on olennainen osa yrityksen toimintaa ja sen toimitusketjua. Varaston tehokas optimointi siis parantaa koko toimitusketjun suorituskykyä, kun tuotteita on paremmin saatavilla ja varaston operatiivinen toiminta on sujuvampaa. Tehokkaammalla optimoinnilla yritys kykenee välttämään myös turhien ylivarastojen syntymisen, jolloin

pääomakustannuksissa voidaan säästää. Säästöjä voidaan tehdä myös esimerkiksi henkilöstökustannuksissa älykkäiden robottien ja dronien avulla.

Tutkielman lopussa käytiin läpi haasteita, joita tekoälyn käyttö tai sen käyttöönotto saattaa aiheuttaa yritykselle. Haasteet liittyivät enimmäkseen osaamattomuuteen ja suuriin investointeihin, joihin tarvitaan paljon pääomaa. Tekoälyn negatiiviset puolet ovat siis pitkälti haasteita, eivät niinkään uhkia. Kirjallisuudessa käsiteltiin yleisesti melko vähän tekoälyn tuomia haasteita. Monissa aihetta käsittelevässä artikkelissa käsiteltiin ainoastaan tekoälyn positiivisia vaikutuksia, eikä negatiivisia vaikutuksia otettu huomioon ollenkaan. Kirjallisuuden ja siten tutkielman pohjalta voidaankin tehdä johtopäätös, että tekoälyn käyttäminen varaston optimoinnissa on kannattavaa, ja että yrityksen tulisi ohjata resurssejaan siten, että se pystyisi tekemään investointeja tekoälyn käyttöönottoa varten.

Kuten alussa todettiin, alalle ei ole vielä muodostunut selkeitä toimintamalleja tai käytänteitä, joiden mukaan olisi tehokkainta toimia. Tekoälyä kuitenkin tutkitaan jatkuvasti, ja teknologian kehittyessä uusia sovelluksia syntyy koko ajan lisää. Näin ollen yritysten tulee olla valmiita kehittämään omaa toimintaansa ja sopeutua alalla tapahtuviin muutoksiin, jotta ne pysyvät mukana nopeasti kiihtyvässä kilpailussa.

Lähteet

- Abu Zwaida, T., Pham, C., & Beaugard, Y. (2021). Optimization of Inventory Management to Prevent Drug Shortages in the Hospital Supply Chain. *Applied Sciences*, 11(6), 2726.
- Agarwal, S. (2014). Economic Order Quantity Model: A Review. *International Journal of Mechanical, Civil, Automobile and Production Engineering*, 4(7), 233–236.
- Al-hamadani, S., & Al-Darraj, I. (2025). Warehouse in industry 4.0 based drone, computer vision, and artificial intelligence technologies: A literature review. *Proceedings on Engineering Sciences*, 7(1), 517–526.
- Bhavikatta, N. B. (2025). AI-Driven Inventory Optimization in Supply Chains: A Comprehensive Review on Reducing Stockouts and Mitigating Overstock Risks. *Journal of Computer Science and Technology Studies*, 7(7), 01–13.
- Chopra, S. (2019). *Supply Chain Management: Strategy, Planning, and Operation* (7. p.). Pearson Education Limited.
- Demiray Kırmızı, S., Ceylan, Z., & Bulkan, S. (2024). Enhancing Inventory Management through Safety-Stock Strategies—A Case Study. *Systems*, 12(7), 260.
- Deng, C., & Liu, Y. (2021). A Deep Learning-Based Inventory Management and Demand Prediction Optimization Method for Anomaly Detection. *Wireless Communications and Mobile Computing*, 2021(1), 9969357.
- Du, K.-L., Zhang, R., Jiang, B., Zeng, J., & Lu, J. (2025). Understanding Machine Learning Principles: Learning, Inference, Generalization, and Computational Learning Theory. *Mathematics*, 13(3), 451.
- Gil, Y., & Perrault, R. (2025). *Artificial Intelligence Index Report 2025*. Stanford University.
- Gonçalves, J. N. C., Carvalho, M. S., & Cortez, P. (2020). Operations research models and methods for safety stock determination: A review. *Operations Research Perspectives*, 7, 100164.
- Gurtu, A. (2021). Optimization of Inventory Holding Cost Due to Price, Weight, and Volume of Items. *Journal of Risk and Financial Management*, 14(2), 65.
- Hangl, J., Krause, S., & Behrens, V. J. (2023). Drivers, barriers and social considerations for AI adoption in SCM. *Technology in Society*, 74, 102299.
- Harrison, A., Skipworth, H., van Hoek, R., & Aitken, J. (2019). *Logistics Management and Strategy* (6. p.). Pearson Education Limited.
- Jean, G. (2024). Inventory Management Strategies: Balancing Cost, Efficiency, and Customer Satisfaction. *ResearchGate*.

- Krajewski, L. J., & Malhotra, M. K. (2022). *Operations Management: Processes and Supply Chains* (13. p.). Pearson Education Limited.
- Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the Artificial Neural Networks. Teoksessa *Artificial Neural Networks—Methodological Advances and Biomedical Applications*. InTech.
- Kreutzer, R. T., & Sirrenberg, M. (2020). *Understanding Artificial Intelligence: Fundamentals, Use Cases and Methods for a Corporate AI Journey* (1. p.). Springer International Publishing.
- Krichen, M., & Mihoub, A. (2025). Long Short-Term Memory Networks: A Comprehensive Survey. *AI*, 6(9), 215.
- Kros, J. F., Falasca, M., & Nadler, S. S. (2006). Impact of just-in-time inventory systems on OEM suppliers. *Industrial Management & Data Systems*, 106(2), 224–241.
- Lee, H. L., Padmanabhan, V., & Whang, S. (1997). The Bullwhip Effect in Supply Chain. *Sloan Management Review*, 38(3), 93–102.
- Li, J., Huang, H., Gong, Y., Wang, L., Yin, X., & Liu, Y. (2025). A Review of Artificial Intelligence in Inventory Management: Methods, Applications and Directions. *International Journal of Advanced Computer Science and Applications*, 16(10), 915–928.
- Ma, X., Wang, Z., Ni, X., & Ping, G. (2024). Artificial intelligence-based inventory management for retail supply chain optimization: A case study of customer retention and revenue growth. *Journal of Knowledge Learning and Science Technology*, 3(4), 260–273.
- Majahar Ali, M. K., Rabi, S., & Ismail, M. T. (2025). *Analytical Inventory Management and Optimization: Theories, Methods and Applications* (1. p.). CRC Press.
- Nobil, A. H., Sedigh, A. H. A., & Cárdenas-Barrón, L. E. (2020). Reorder point for the EOQ inventory model with imperfect quality items. *Ain Shams Engineering Journal*, 11(4), 1339–1343.
- Nortio, J. (2026). Tekoäly vauhdittaa Bernerin liiketoimintaa. *Osto&Logistiikka*, (1), 16–17.
- Ray Silaen, B., Nasution, M., & Muti'ah, R. (2024). Implementation of the ABC Analysis to the Inventory Management. *International Journal of Science, Technology & Management*, 5(4), 816–825.
- Sagheer, A., & Kotb, M. (2019). Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*, 323, 203–213.
- Sheikh, H., Prins, C., & Schrijvers, E. (2023). *Mission AI: The New System Technology* (1. p.). Springer International Publishing.
- Silver, E. A., Pyke, D. F., & Thomas, D. J. (2017). *Inventory and production management in supply chains* (4. p.). CRC Press.

- Tadjine, C., Ouafi, A., Benlamoudi, A., & Taleb-Ahmed, A. (2025). Computer vision in warehouse management automation: A survey on implemented methods with prototyping hardware. *Engineering Applications of Artificial Intelligence*, *160*, 111886.
- Taye, M. M. (2023). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers*, *12*(5), 91.
- van den Bogaert, J., & van Jaarsveld, W. (2021). Vendor-managed inventory in practice: Understanding and mitigating the impact of supplier heterogeneity. *International Journal of Production Research*, *60*(20), 6087–6103.
- Van Houdt, G., Mosquera, C., & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, *53*(8), 5929–5955.
- Wang, B. (2019). The cash conversion cycle spread. *Journal of Financial Economics*, *133*(2), 472–497.
- Zöls, K., Braun, D., Siciliano, G., & Fottner, J. (2024). An Artificial Intelligence Based Method For Optimized Warehouse Storage Allocation. *Conference on Production Systems and Logistics*, 432–442.

Liitteet

Liite 1 Selvitys tekoälyn käytöstä

Tämän tutkielman tekemiseen on käytetty apuna tekoälyä. Käytettävät ohjelmat ovat olleet seuraavat: ChatGPT versio 5.3, Google Gemini, Scopus AI ja DeepL. Alla on esitelty, miten kutakin ohjelmaa on käytetty.

ChatGPT versio 5.3 & Google Gemini

- Aiheen ideointi ja rajausta
- Rakenteen suunnittelu ja muotoilu
- Lähteiden etsiminen
- Artikkeleiden tiivistäminen
- Kielenhuolto

Scopus AI

- Lähteiden etsiminen

DeepL

- Lauseiden ja artikkeleiden osien sekä käsitteiden suomentaminen

Alla on esitetty kaksi esimerkkiä siitä, millaisia kehoitteita tekoälylle on annettu.

- ChatGPT versio 5.3: ”Teen kandia tekoälyn hyödyntämisestä varaston optimoinnissa. Miten voisit hyödyntää yllä olevia artikkeleita? Mitä keskeisiä asioita niissä käsitellään?”
- Google Gemini: ”Alla on tämänhetkinen kandini tekoälyn hyödyntämisestä varaston optimoinnista. Olen käsitellyt varaston optimointia ja tekoälyä erikseen omissa kappaleissaan ja seuraavassa luvussa luvussa yhdistän ne eli tarkastelen konkreettisia tapoja hyödyntää tekoälyä varaston optimoinnista. Minkälainen rakenne kappaleessa kannattaisi olla ja mitä aiheita kannattaisi käsitellä?”

Tekoälyä ei ole käytetty tekstin tuottamiseen tai johtopäätösten tekemiseen. Vakuutan, että tekoälyä on käytetty yliopiston ohjeistuksen mukaisella tavalla.