Kirill Karppi

Sisäisen logistiikan tehostaminen tekoälyn avulla

Tekniikan ja innovaatiojohtami-
sen yksikkö
Kandidaatintutkielma, tuotan-
totalous
Tekniikan kandidaatti

Vaasa 2025

VAASAN YLIOPISTO
Tekniikan ja innovaatiojohtamisen yksikkö
Tekijä: Kirill Karppi
Tutkielman nimi: Sisäisen logistiikan tehostaminen tekoälyn avulla
Tutkinto: Tekniikan kandidaatti
Oppiaine: Tuotantotalous
Työn ohjaaja: Tauno Kekäle
Valmistumisvuosi: 2025 **Sivumäärä:** 40

TIIVISTELMÄ:
Tutkielman tavoitteena on perehdyttää lukija sisäisen logistiikan merkitykseen ja rakenteeseen eri vaiheiden kautta, sekä esitellä tekoälyjärjestelmien rakentamisen ja kouluttamisen periaatteet. Lisäksi tutkielmassa tarkastellaan tekoälyn integraatiota sisäisen logistiikan prosesseihin sekä sähköisellä että fyysisellä tasolla. Tavoitteena on myös osoittaa tekoälyn integraation kannattavuus nykyisissä sisälogistiikan toimintaympäristöissä ja korostaa sen merkitystä yritysten kilpailukyvylle nykypäivän markkinoilla.

Sisäisen logistiikan rakenteelle ei ole olemassa yhtä absoluuttista tai universaalia mallia. Jokainen organisaatio suunnittelee logistiikkaprosessinsa omien tarpeiden ja materiaalivirtojen mukaisesti. Tästä huolimatta sisäisen logistiikan keskeiset vaiheet ovat pääosin samankaltaisia, ja niillä on kriittinen rooli koko prosessin toimivuuden kannalta. Sama periaate pätee myös tekoälyjärjestelmiin. Vaikka markkinoilla on tarjolla laaja valikoima erilaisia tekoälyratkaisuja, jokainen järjestelmä on suunniteltava tiettyä tehtävää varten. Tässä tutkielmassa korostetaan tekoälyjärjestelmien yksilöllistä ja tehtäväkohtaisuutta sekä niiden rakenteellista suunnittelua.

Tutkielman loppuosassa keskitytään tekoälyn integraation sisäisen logistiikan järjestelmiin. Integraatio-osassa tarkastellaan sekä sähköisen että fyysisen integraation ominaisuuksia ja vaikutuksia. Lisäksi analysoidaan, miten nykyaikaiset viitekehitykset ja standartit kuten Quality Management 4.0, Lean 4.0, Six Sigma 4.0 ja ISO-standartit vaikuttavat tekoälyjärjestelmien päätöksentekoon ja suorituskykyyn. Viimeisessä osiossa esitetään kansainvälisten, johtavien yrityksien raportointiin perustuvia tuloksia. Tuloksissa osoitettiin tekoälyn merkittävän potentiaalin tehostamisen kannalta verrattuna perinteisiin ja yksinkertaisempiin järjestelmiin.

AVAINSANAT: tekoäly, logistiikka, automaatio, algoritmit, varastot, koneoppiminen, syväoppiminen

Sisällys

1 Johdanto 6
1.1 Tutkielman taustaa ja konteksti 6
1.2 Nykytilanne 7
1.3 Tavoitteet 7
2 Sisäinen logistiikka 9
2.1 Sisäisen logistiikan määritelmä 9
2.2 Sisäisen logistiikan vaiheet 11
2.3 Sisäisen logistiikan ohjelmistot 13
2.4 Täydentäviä järjestelmiä 14
3 Tekoälyn tekninen rakenne 16
3.1 Tekoälyn perusteet 16
3.2 Tekoälyn opettaminen 18
3.2.1 Koneoppimisen perusidea 18
3.2.2 Datanlaatu ja valmistelu 18
3.2.3 Opetusmenetelmät 19
3.3 Neuroverkot 20
4 Tekoälyn integrointi sisäiseen logistiikkaan 22
4.1 Tekoälyn sähköinen integrointi sisäiseen logistiikkaan 22
4.2 Tekoälyn integrointi sisälogistiikan ohjelmistoon 25
4.3 Fyysinen integrointi 26
4.4 Standardien vaikutus 28
4.5 ISO-standardit 29
4.6 Tekoälyn vaikutukset sisälogistiikan tehokkuuteen 31
4.6.1 ERP ja tekoäly 32
4.6.2 WMS ja tekoäly 33
4.6.3 MES ja tekoäly 33
4.6.4 AGV/AMR-robotit 33

4.6.5 Konenäkö 34

4.6.6 Standardit 34

5 Yhteenveto 35

Lähteet 37

Kuvat

Kuva 1 Sisäisen logistiikan prosessi (Logistiikan Maailma, 2025) 11

Kuviot

Kuvio 1 Logistiikan osa alueiden kustannusjako (Federal Highway Administration [FHWA], 2005). 10

Kuvio 2 Neuroverkkojen rakenne (Merilehto, 2018) 21

1 Johdanto

1.1 Tutkielman taustaa ja konteksti

Tekoälyn kehitys alkoi jo 1900-luvun puolivälissä teoreettisilla malleilla, mutta sen käytännön soveltaminen teollisuuskäyttöön alkoi huomattavasti myöhemmin. Ensimmäiset teolliset kokeilut aloitettiin 1990-luvulla (Logycco, 2023). Silloin yritykset alkoivat hyödyntää sääntöpohjaisia tekoälymenetelmiä, esimerkiksi tuotannon ajoituksessa ja laadun arvioinnissa. Samaan aikaan kehittyivät myös modernien yritysjärjestelmien varhaisvaiheet, kuten ensimmäiset ERP järjestelmät (Wallace & Kremzar, 2001). ERP-järjestelmät loivat pohjan kokonaisvaltaisten materiaalivirtojen hallinnalle. Tuon ajan sovellukset osasit yhdistää varastonhallinnan (WMS), kuljetus suunnittelun (TMS), sekä hankinnan ja tuotannon ohjauksen yhdeksi kokonaisuudeksi. Tämä käynnisti sisäisen logistiikan systemaattisen digitalisaation.

Vaikka tekoälyä pystyttiin liittämään ERP-järjestelmiin jo varhaisessa vaiheessa ohjelmointirajapintojen (Application Programming Interface, API) kautta, ratkaisut eivät olleet autonomisia, eivätkä sisältäneet nykyaikaisia oppimismalleja (Machine Learning. ML). Varsinainen läpimurto tapahtui vasta 2010-luvulla, jolloin ML-mallit kehittyivät ja niiden laskentateho mahdollisti datan perustuvan päätöksenteon automatisointiin (Manyika, 2013).

Ensimmäiset kaupalliseen tarkoitukseen kehityt ERP-järjestelmät, joissa ML-mallit olivat sisäänrakennettuna osana järjestelmän ydintoiminta, julkaistiin vuonna 2015. Näissä järjestelmissä tekoäly kykeni tuottamaan ennusteita, optimoimaan varastoja ja analysoimaan sisään tulevaa dataa autonomisesti (SAP SE, 2015). Tämä kehitys mahdollisti kasvua tekoälyn roolia sisäisessä logistiikassa.

1.2 Nykytilanne

Tekoälyn hyödyntäminen sisäisessä logistiikassa on yleistynyt merkittävästi viimeisten vuosien aikana ja teknologia on siirtynyt kokeiluasteelta kohti laajamittaista teollisuus käyttöönottoa. Yritykset ovat alkaneet integroimaan yhä enemmän koneoppimiseen ja syväoppimiseen perustuvia tekoälyjärjestelmiä. Ne ovat mahdollistaneet ennakoivan analytiikan soveltamista, erityisesti varastonhallinnan, materiaalivirojen optimoinnin sekä tuotannonohjaukseen. Kansainväliset yritykset, kuten Deloitte (2024) ja McKinsey (2023), ovat raportoinnissa osoittaneet, että yli puolet suurista teollisuusyrityksistä hyödyntää jo tekoälypohjaisia ratkaisuja logistiikan suunnittelussa ja operatiivisessa ohjauksessa.

Tämä kehityssuunta ei näy ainoastaan yksittäisten yritysten toimintamalleissa, vaan myös standardisoinnin uudistumisessa. Vuonna 2017 julkaistu Quality Management 4.0 (QM 4.0) on suunniteltu tukemaan organisaatioiden digitalisoitumista ja datan perusteista laadunhallintaa (American Society for Quality [ASQ], n.d.). Digitalisaation eteneminen ei ainoastaan tuonut uusia standardeja tekoälyn integrointia varten, vaan kiihdytti myös laitteistojen ja sensoriteknologioiden kehitystä. Sen seurauksena sisäiseen logistiikkaan integroidaan yhä useammin fyysisiä tekoälyjärjestelmiä, kuten AGV/AMR-robotteja sekä IoT-pohjaista laitteistoa.

Tekoälyn laajentava rooli ei tuo mukanaan pelkästään teknologisia innovaatioita, vaan myös merkittävää kilpailuetua. Tekoäly mahdollista yrityksille toimintaprosessien optimoinnin ja tehostamisen. Se myös parantaa päätöksenteon laatua simulaatioiden ja reaaliaikaisen datan avulla, sekä vähentää työvoimakustannuksia ja virheitä.

1.3 Tavoitteet

Tämän tutkielman tavoitteena on tarkastella, miten tekoälyn integraatio sisäiseen logistiikkaan tapahtuu ja millaisia vaikutuksia sillä on prosessien tehostamiseen.

Tutkielma pyrkii kuvaamaan sekä integroivan teknologian rakenteen, että sen konkreettisen vaikutuksen. Tutkielman ensimmäinen luku toimii johdantona, joka perehdyttää lukijan tekoälyn ja sisäisen logistiikan ohjelmistojen varhaisiin kehitysvaiheisiin sekä nykytilanteeseen.

Toisessa luvussa tutkielma käsittelee sisäisen logistiikan määritelmää ja sen roolia toimitusketjussa. Lisäksi kappaleessa avataan sisälogistiikan yleinen rakenne ja kuvataan prosessin eteneminen vaiheittain.

Kolmannessa luvussa syvennytään tekoälyn toimintaan. Osio käsittelee tekoälyn algoritmeja sekä koneoppimisen opetusmenetelmiä ja tarkastelee niiden välisiä eroja ja mahdollisuuksia sisäisen logistiikan näkökulmasta.

Neljännessä luvussa tarkastellaan tekoälyn integraatiota sisäisen logistiikan verkostoon sekä sähköisellä että fyysisellä tasolla. Lisäksi käsitellään, mihin tekoäly järjestelmien päätöksenteko perustuu ja millaisiin rakenteisiin se nojautuu. Kappaleen lopussa esitetään kooste yleisimmistä tehostus vaikutuksista verrattuna perinteisiin järjestelmiin.

2 Sisäinen logistiikka

2.1 Sisäisen logistiikan määritelmä

Logistiikka maailman (2025) mukaan, sisäinen logistiikka on tehtaan terminaalin tai varastojen aitojen sisäpuolella tapahtuvaa materiaali- ja informaatiovirtojen hallintaa sekä niiden kehittämistä. Sisäinen logistiikka voidaan myös määritellä talon sisäiseksi logistiikaksi (Winkler & Zinsmeister, 2019).

Sisäinen logistiikka on keskeinen osa organisaatiotoimintaa ja on kriittisessä roolissa organisaatioiden kehityksessä. On tärkeää huomioida, että logistiikan alueen kehittäminen tähtää kokonaisvaltaiseen ja johdonmukaiseen kustannusorientoitumiseen (Gleissner, & Femerling. (2013). Miettiessämme sisäistä logistiikkaa, on myös tarpeen luoda sujuva ketju alusta loppuun asti sillä se ei pelkästään vaikuta sisäiseen mutta myös ulkoiseen logistiikkaan laaja-alaisesti (Ghiani, 2013).

Federal Highway Administration [FHWA], 2005 mukaan sisäisen logistiikan osuus kokonais- yrityskustannuksista on 1/3 tai vaihtoehtoisesti 33 % (Kuvio 1). Sujuva ja hyvin laadittu materiaali sekä informaatiovirtojen prosessi tehostaa merkittävästi yritysten toimintoja, vähentää huomattavasti kustannuksia ja lisää asiakastyytyväisyyttä. Varastonhallinnan ja sisäisen logistiikan hyvä johtaminen vaikuttavat laajalti toimitusketjun suorituskykyyn (Curcio & Longo, 2010).

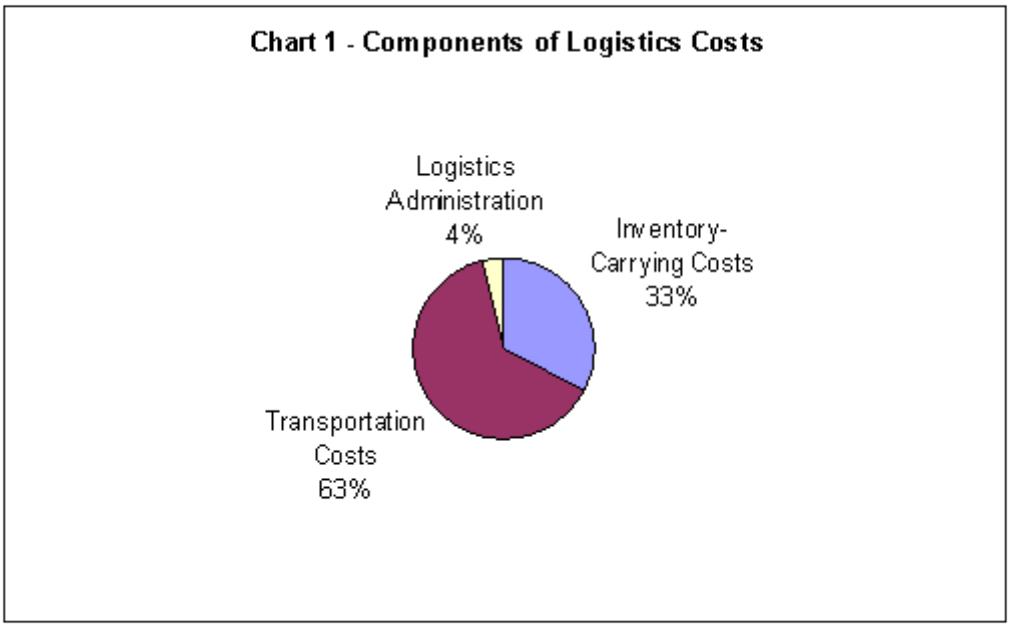

Kuvio 1 Logistiikan osa alueiden kustannusjako (Federal Highway Administration [FHWA], 2005).

Sisäisen logistiikan rakenteet vaihtelevat paljon organisaation tarpeiden mukaisesti. Rakenteisiin vaikuttavat organisaation toimiala sekä materiaalivirrat. Sisäisen logistiikan prosessit vaativat tarpeidensa mukaista infrastruktuuria. Infrastruktuurin ei kuitenkaan tarvitse sijaita samalla alueella vaan voi olla jakautunut monelle eri alueelle. Ghiani (2013) toteaa varastomäärien kasvaessa, etäisyys infrastruktuurin ja asiakkaiden välillä vähenee, kun taas kokonaisetäisyys logistisen järjestelmän aiemmista toimipaikoista kasvaa. Tämän vuoksi on tärkeä suunnitella yhtenäinen ja optimoitu materiaalivirran ketjun alusta loppuun (Ghiani, 2013).

Tehokkaan sisälogistiikan prosessin toteuttaminen edellyttää hyvin suunnitellun infrastruktuurin lisäksi myös tarkan tiedonhallintajärjestelmän. Useimmin organisaatiot hyödyntävät yleiset resurssihallintaohjelmistot kuten ERP (Enterprise Resource Planning) sekä WMS (Warehouse Management system), jotka mahdollistavat reaaliaikaisen materiaalivirtojen hallinnan (Grand View Research, 2025). Joissakin tapauksissa organisaatiot voi hyödyntää myös omia, räätälöityjä ohjelmistoratkaisuja tai ohjelmistoympäristöjä. Ohjelmiston rooli sisäisessä logistiikassa on suuri, sillä se takaa

organisaatiolle läpinäkyvyyttä, parantaa resurssinhallintaa, datan laatua ja prosessien reaaliaikaista hallintoa.

2.2 Sisäisen logistiikan vaiheet

Logistiikan maailman (2025) määritelmän mukaan sisäisen logistiikan prosessi muodostuu materiaalin vastaanottamisesta, hyllytyksestä, sisäisitä siirroista, keräilystä, pakkaamisesta, lastaamisesta sekä kierrätyksen hallinnasta. Fyysinen prosessi on kuitenkin huomattavasti monimutkaisempi ja muotoutuu organisaation tarpeiden ja tuotantorakenteiden mukaisesti.

Sisäisen logistiikan kokonaisuus jaetaan kolmeen päävaiheeseen (Kuva 1), jotka parhaillaan kuvaavat organisaation prosessia. Saapuva logistiikka (Incoming Logistics), tuotannon logistiikka (Production Logistics) sekä lähtevä logistiikka (Outgoing Logistics) (Buzinkay, 2025). Saapuvan logistiikan voimme jakaa kolmeen ala otsikkoon. Vastaanotto ja tarkistus, varastointi ja sijoittelu sekä varaston täydennys. Saapuvan logistiikan vaihe alkaa vasta kun materiaali on ylittänyt organisaation alueen ja siirtynyt sen käsittelyyn.

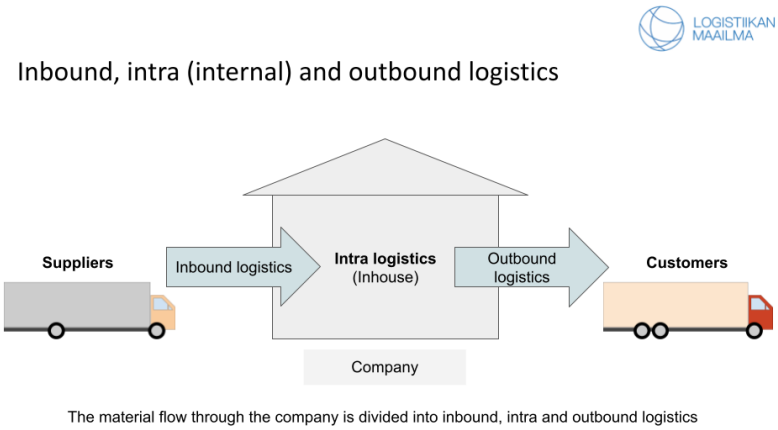

Kuva 1 Sisäisen logistiikan prosessi (Logistiikan Maailma, 2025)

Saapuvan logistiikan ensimmäinen vaihe on materiaalin vastaanotto, jossa tarkistetaan materiaalin oikeellisuutta sekä kuntoa, ennen materiaalin siirtämistä seuraavan työvaiheeseen. Vastaanoton tehokkuutta mitataan läpimenoajalla, joka kuvaa prosessin nopeutta ja kapasiteettia täyttää operatiiviset tarpeet (Logistiikkamaailma, 2025). Käytännössä vastaanotto sisältää toimitusten purkamista tuotteiden määrän ja laadun tarkistamiseen sekä tietojen kirjaaminen tietokantoihin. Useasti toimitetun materiaalin määrä kirjataan yrityskäytössä olevaan resurssiohjelmistoon, joka voi olla joko WMS tai ERP ohjelmisto. Näiden avulla varaston tietokannat päivittyvät reaaliaikaisesti.

Vastaanoton jälkeen materiaali siirtyy varastoinnin puolelle joko manuaalisesti, automaattisen kuljetinlinjaston kautta tai robotiikan avulla. Yritys itse suunnittelee tarpeet täyttävän varastointialueen (Ghiani, Laporte & Musmanno, 2004).

Varaston toiminta on mahdollista automatisoida ja sen automatisaation kyky riippuu täysin yrityksen toiminta ympäristöstä. Pienikokoisten organisaatioiden varastoissa on riittävä määrä manuaalista voimaa, kun taas isoimmissa ja automatisoiduissa on ennemmin panostettu robotiikkaan (Stufano, 2024). Molempien toimintojen tärkeys vaihtelee varaston tyypin, nimikkeiden määrän ja kysynnän mukaan (Ghiani, 2013). Varaston rooli on tukea yrityksen tasaisen tuotantotahdin ylläpitämistä sekä minimoida kustannuksia pitämällä varastotasot optimaalisia suhteessa kysyntään (Ghiani, 2013).

Intralogistiikka muodostaa sisäisen logistiikan ytimen. Se kattaa kaikki toiminnot, joiden avulla saapuvasta materiaalista muutetaan raaka-aineiksi ja siitä valmiiksi tuotteiksi. Intralogistiikan päätehtävä on varmistaa, että materiaalivirta tuotannon pisteiden välissä on saumaton ja nopea. Se yhdistää materiaalitarjonnan, sisäiset siirrot sekä työn alla olevan materiaalin (WIP, Work in progress). Materiaalitarjonta on erityisen kriittisin vaihe. Sillä se varmistaa materiaalistarjonnassa on toimitettavien komponenttien ja raaka aineiden oikea-aikaista ja täsmällistä toimittamista tuotantoon. Jotta tuotantoprosessi ei keskeydy. Se toteuttaa (Just-In-Time, JIT) periaatteetta ja varmistaa että sisäiset siirrot tuovat materiaalit juuri silloin kun niitä tarvitaan. Tästä puolestaan

vastaa varaston sisäiset siirrot. Sisäiset siirrot toteutetaan automatisoidusti, ja erityisesti raskaat ja toistuvat siirrot. AGV ja AMR robotit hoitavat materiaalin kuljetuksen itsenäisesti sisäinen logistiikan alueella tarpeiden mukaisesti. WIP materiaalin siirrot sisältävät puolivalmiiden tuotteiden fyysisen puskuroinnin tuotantopisteiden välillä.

Kuin materiaalin on valmistunut, siirrytään sisäiseen logistiikan viimeiseen vaiheeseen, eli lähtevään logistiikkaan. Lähtevä logistiikka sisältää valmiiden tuotteiden varastoinnin, tilausten keräilyn ja kokoamisen, pakkaamisen, lähetyksen esikäsittelyn sekä lastauksen ja luovutuksen.

2.3 Sisäisen logistiikan ohjelmistot

Intralogistiikan tiedonhallintajärjestelmät sekä automaatio- ja robotiikkaa ratkaisut muodostavat yrityksen tehokkuuden ja toimintavarmuuden perustan. Digitaaliset tiedonhallinnat luovat toiminnasta läpinäkyvän ”digitaalisen kaksoisversion”, joka mahdollistaa reaaliaikaisen päätöksenteon sekä hallita koko intralogistiikan ketjua saapuvasta tavarasta lähetykseen. (Smartlogistix, n.d.) ja (Logiwa, n.d.)

Selkärangan tiedonhallintaan infrastruktuurille puolestaan luo ERP eli (Enterprise Resourse planning) sekä varastonhallinta järjestelmä eli WMS (Warehouse management System). Nämä järjestelmät toimivat toisiaan täydentäen. ERP vastaa operatiivisten ja taloudellisten kokonaisuuksien hallinnasta, kun taas WMS optimoi varaston päivittäisen toiminnan.

ERP-järjestelmä puolestaan hallitsee MRP eli materiaalitarpeita ohjaavasta järjestelmästä ja taloudellisesta arvonmääräyksestä (Canon, 2025). Lisäksi ERP määrittää mitä ja milloin logistiikalle on siirrettävä. Mutta se ei yleensä optimoi miten siirto tapahtuu (IBM, n.d.).

MRP puolestaan pyrkii laskemaan myyntitilausten ja tuotantosuunnitelmien perusteella tarkan tarpeen raaka-aineille sekä komponenteille mitä on hankittava. Sekä taloudellinen arvonmääritys kirjaa varaston arvon ja ylläpitää kokonaiskuvaa varastontilanteesta taloushallinnon tarpeisiin. (Aligni, n.d.)

WMS puolestaan toimii ERP:n operatiivisena jatkeena ja sisälogistiikan ohjauskeskuksena. WMS järjestelmä on suunniteltu optimoimaan kaikki varaston ja tuotannon liikkeet, kuten vastaanoton, hyllytyksen, keräilyn, siirrot ja lähetyksen. Sen avulla voimme purkaa tehtävänannot, jotka saapuvat ERP ohjelmistosta. WMS puolestaan laskemalla optimoi varaston toimivuuden, laskemalla tehokkaimmat keräily ja siirtoreitit. Lisäksi WMS jakaa työtehtävän henkilöstölle ja työnkulusta (SAP, n.d). On kuitenkin tärkeä huomioida, että WMS on vain täydentävä sovellus, joka toimii ERP ja työntekojen rinnalla.

2.4 Täydentäviä järjestelmiä

Vaikka sisäisen logistiikan ohjaus tapahtuu pääasiassa ohjelmiston avulla, fyysinen tehokkuus syntyy automaatiosta ja tarkan tunnistusteknologian ansiosta. Prosessin eri vaiheissa voidaan integroida apujärjestelmiä, kuten RFID, QR ja viivakoodi tunnistimet prosessin jokaisella vaiheella. Nopeat tunnistukset ja jäljitys mahdollistavat materiaalin nopean rekisteröinnin tietokantaan sekä seurantaa koko prosessin läpi. (Zyllem, n.d.)

Ohjelmiston lisäksi sisäisen logistiikan järjestelmät voivat sisältää automatisoituja materiaalikäsittelyratkaisuja, jotka toimivat WMS-järjestelmän ohjaamina. Niiden päätehtävänä on tuottaa siirto- ja keräilykäskyjä manuaalisesti.

Varastoinnin automatisaatio voidaan toteuttaa AS/RS (Automated Storage and Retrieval System) -järjestelmien sekä puskurivarastojen avulla (Hameed, 2019). AS/RS malliset varastoinnin tyypit sisällyttävät korkeat sekä tiiviit hyllystöt, joissa nosturibotit huolehtivat tuotteiden sisäänviennistä sekä noudosta varastopaikoilta. Vastaavasti

puskurivarastot toimivat lyhytaikaisena, tiiviinä säilytysratkaisuna tuotteille ja materiaalille. Puskurivarastot säilyttävät materiaalia, joita tarvitaan pian tuotannossa tai keräilyssä.

Näiden järjestelmien rinnalla toimii myös automatisoitu kuljetus ja siirrot. Kuljetuksista vastaa Joko AGV, AMR tai muut kuljetusjärjestelmät (Keith & Feil-Seifer, 2024).

”Automated guided vehicle” tai AGV ovat automaattitrukkeja, jotka operoivat valmiiksi luoduilla reiteillä. AGV ovat useammin tarkoitettuja rutiininomaisiin, toistautuvien kuljetuksiin varastoon ja tuotantopisteiden välillä.

Autonomous Mobile Robot tai AMR ovat AGV robotteja älykkäämpi versio. AMR robotit voivat itsenäisesti navigoida varastoinnin puolella valmiiksi luotujen karttojen avulla sekä väistää mahdollisia esteitä. AGV botit voivat dynaamisesti muokkailemaan omia reittejä WMS antamien tehtävien mukaisesti (Turlapati, 2021).

Yksinkertaisemmissa sisälogistiikkajärjestelmissä useasti käytettävissä on mekaanisia kuljetinjärjestelmiä, kuten rulla-, ketju- ja hihnakuljettimia.

3 Tekoälyn tekninen rakenne

Luvussa kolme tarkastellaan tekoälyn teknistä rakennetta ja periaatteita sekä sitä, minkä pohjalta tekoälyllä varustetut järjestelmät tekevät päätöksiä ja tuottavat tuloksia. Tekoälyn sopeutumiskyky mahdollista tekoälyjärjestelmien integroimisen organisaatioidenympäristöihin, jossa se toimii prosessien tehostustyökaluna.

Luku kolme etenee tekoälyn perusteista, kohti tekoälyn alkukehitykseen rakennetta, eri runkorakenteisiin ja koneoppimismenetelmiin. Lopuksi tarkastellaan syväoppimisen ja neuroverkostojen toimintaa kehittyneissä tekoälyjärjestelmissä.

3.1 Tekoälyn perusteet

Tekoäly eli englanniksi Artifical Intelligence, integraatio organisaatiojärjestelmiin on alkanut jo vuosikymmeniä sitten, kun vuonna 1956 IBM ensimmäistä kertaa esitteli tekoälyn mahdollisuuksia ja sen kykyä tehostaa rutiinimaisia tehtäviä, mikä puolestaan loi perustan jatkokehitykselle. (University of Alberta, 2025), (IBM, n.d.).

Mutta mikä AI oikeastaan on? Artificial intelligence, lyhenteenä AI, viittaa koneoppimiseen perustuvaan ohjelmistoon, joka suurien datamäärien avulla pystyy oppimaan, sopeutumaan ja ratkaisemaan erilaisia ennalta määriteltyjä tehtäviä. Jokainen tekoälyjärjestelmä luodaan tehtävänkohtaisesti. Tekoäly ei ole yksi teknologia, vaan joukko menetelmiä sekä algoritmeja. Niiden avulla järjestelmä pystyy päättelemään, ennustamaan ja optimoida toimittaa sille määrityn datan avulla (Stryker & Kavlakoglu, n.d.).

Jokainen tekoälyjärjestelmä rakentuu tietyn tehtävän ympärille, ja sen toiminta ja päätöksenteko määrity tehtävän mukaisen algoritmin avulla. Algoritmi ohjaa AI, miten järjestelmää lähestyy sekä käsittele dataa. Myös miten se hyödyntää sitä opetuksessa ja millaisia lopputuloksia AI pystyy tekemään sen pohjalla. Näin olleen tekoälyn onnistunut

hyödyntäminen vaati, että sen tehtäväalueet ja tarpeita ulostulona tunnistetaan jo kehitysvaiheessa. (Merilehto, 2018).

Tekoälyn kehittämiseen alkuvaiheessa on tärkeä määrittää mihin tarkoitukseen ja mihin tehtävään tekoälyjärjestelmä luodaan, sillä tekoälyn ”aivot” ja arvot perustuvat algoritmeihin, jotka ohjaavat järjestelmän toimintalogiikkaa. Algoritmit määrittävät, miten tekoäly käsitelle dataa, oppii, luo päätöksiä ja tuottaa tuloksia (Kananen & Puolitaival, 2019)

Algoritmit ohjaavat koneoppimista ja asettavat arvot, rajat ja ehdot, joiden perusteella annettua dataa hyödynnetään. Organisaatioiden prosessit ovat erittäin yrityskohtaisia ja algoritmit suunnitellaan toimitaan tiettyjen tehtävien mukaisesti. Vaikka joitakin valmiita mallipohjia on olemassa, universaalia algoritmia, joka sopisi jokaiseen tilanteeseen ja ratkaisisi kaikki ongelmat, ei ole olemassa (Merilehto, 2018). Mikäli yrityksen käytössä ei ole valmista pohjaa, algoritmi kehitetään tehtäväkohtaisesti.

Kaikki tällä hetkellä käytössä olevat tekoälyjärjestelmät perustuvat niin kutsuttuun kapeaan tekoälyjärjestelmään (Artifical Narrow Intelligence, ANI), joka suunniteltu suorittamaan yksi rajattu tehtävä erittäin tehokasti (Merilehto, 2018). AI ei kykene laajentamaan osaamista muihin tehtäviin samanaikaisesti tai toimimaan tehtävämääräyksen ulkopuolella, mikä erottaa sen kehittyneemmästä ideologisesta laajasta tekoälystä (AGI)

ANI:n vahvuus on sen tarkkuus ja suorituskyky rajatuissa sovelluksissa. Se kykenee käsittelemään suuria datamääriä ja tunnistamaan säännönmukaisuuksia sekä epälineaarisia poikkeamia, jota perineinten ohjelmisto tai ihminen ei välttämättä havaitse (Kananen & Puolitaival, 2019). ANI toimii kuitenkin vain sille määritellyissä rajoissa eikä kykenee sopeutumaan täysin uudenlaisiin tilanteisiin ilman erillistä mallinnusta. Tämä rajallisuus erotta sen merkittävästi laajasta tekoälystä (Artificial

General Intelligence, AGI), joka teoreettisesti kykenisi dynaamisesti oppimaan ja sopeuttamaan tilanteisiin sekä soveltamaan tietoa eri tehtäväalueisiin. (Ojanperä, 2023.)

3.2 Tekoälyn opettaminen

3.2.1 Koneoppimisen perusidea

Tekoälyn oppiminen perustuu Machine Learning (ML) eli koneoppimiseen, joka on tekoälyn osa alue, jonka avulla järjestelmä kykenee oppimaan datasta ilman, että sen toimintaa tarvitse jatkuvasti ohjelmoida manuaalisesti tai yksityiskohtaisesti (Merilehto, 2018). Koneoppimisen algoritmit rakentuvat vaiheittaiselle oppimiselle: malli tarkastelee syötettyä dataa, tunnistaa siitä rakenteita ja kehittää vähitellen kyvyn tehdä luokitteluja, ennusteita tai päätöksiä. (Kananen & Puolitaival, 2019)

Algoritmit puolestaan määrittävät koneoppimisen säännöt, rajat, arvot ja toiminta menetelmät. Kun tekoälyjärjestelmän tarkoitus on tunnistetta ja sille on valittu tehtävän mukainen algoritmi, takaa tekoälyn varsinainen koulutus. Koulutus puolestaan tapahtuu erikokoisten ja erilaisten datamassojen avulla. Datamassojen määrä riippuu puolestaan opetusmenetelmästä (Kananen & Puolitaival, 2019).

3.2.2 Datanlaatu ja valmistelu

Koneoppimisen onnistuminen riippuu voimakkaasti käytettävän datan laadusta ja määrästä. Ennen mallin kouluttamista, dataa on tärkeätä suodattaa ja puhdistaa, jotta siitä poistetaan virheelliset, puutteelliset tai vanhentunet havainnot (Merilehto, 2018). Heikkolaatuinen data voi johtua esimerkiksi puutteellisista tietokannoista, virheellisesti toimivista sensoreista/antureista, puuttuvista merkinnöistä tai epätarkkuudesta datan keräyksessä. Kaikki nämä voivat johtaa virheellisiin johtopäätöksiin ja heikentää AI mallin tarkkuuttaa.

Korkealaatuinen ja suodattuu data tuottaa tarkempia ja luotettavampia tuloksia verrattuna heikkolaatuisempaan dataan. Tyypillisesti koneoppimisen datan voidaan

jakaa seuraavasti: perusdata, josta tehtävän kokonaisuus muodostuu, opetusdata, jolla mallia koulutetaan sekä testidata, jolla arvioidaan mallin toimivuutta (Kananen & Puolitaival, 2019).

Mallin tarkoituksena on oppia opetusdatasta ennustamaan tai luokittelemaan tulevia havaintoja, ja testidatan avulla varmistetaan, kuinka hyvin oppiminen on onnistunut. Vaikka suuret datamassat parantavat mallien tarkkuutta, tietyissä tilanteissa voidaan edetä myös pienemmillä aineistoilla, mikäli datan laatu on korkea (Merilehto, 2018).

3.2.3 Opetusmenetelmät

Tyypillisesti koneoppimiseen menetelmät jaetaan kolmeen pääluokkaan. Ohjattu oppiminen eli (supervised learning, SL), ohjaamaton oppiminen (unsupervised learning, UL) ja sekä vahvistusoppiminen (Reinforced Learning, RL) (Kananen & Puolitaival, 2019).

Ohjattu oppiminen perustuu valmiiksi merkittyyn dataan, jossa jokainen esimerkki on lineaarinen ja sisältää sekä syötearvon että oikean vastauksen. Malli pyrkii oppimaan näiden välisen yhteyden ja tuottamaan jatkossa mahdollisimman tarkan ennusteen uusille syötteille. Tämä menetelmä soveltuu erityisen hyvin luokitteluun, ennustamiseen ja numeerisiin optimointitehtäviin, joissa data on rakenteeltaan selkeää (Kananen & Puolitaival, 2019).

Ohjaamattomassa oppimisessa dataa ei ole valmiiksi merkittyä. Mallin tehtävä on etsiä datasta rakenteita, kuten ryhmiä, samankaltaisuuksia, riippuvuuksia ja poikkeamia. Tämä lähestymistapa soveltuu esimerkiksi klusterointiin, asiakas- tai tuoteryhmittelyyn, varaston poikkeamien tunnistamiseen sekä tilanteisiin, joissa datan käyttäytyminen on monimutkaista tai epälineaarista. (Merilehto, 2018). Vaikka data on sekalaista, sitä on kuitenkin suodettava ennen käyttöä.

Vahvistusoppiminen poikkeaa kahdesta edellisestä opetusmenetelmästä, sillä se ei vaadi suuria datamassoja. Sen sijaan malli oppii tekemään päätöksiä kokeilemalla ja saamalla

palautetta toiminnastaan. Esimerkiksi, tekoäly arvioi tilannetta, valitsee toiminnon ja saa positiivisen tai negatiivisen "palkkion". Menetelmä soveltuu erityisesti dynaamisiin ympäristöihin, kuten robotiikkaan, konenäköön ja varaston automaatioon.

3.3 Neuroverkot

Syväoppiminen eli Deep Learning, DL on koneoppimisen alalaji, joka perustuu keinotekoisiin neuroverkkoihin. Syväoppiminen on noussut keskeen rooliin moderneissa tekoälysovelluksissa, koska se kykenee mallintamaan monimutkaisia ja epälineaarisia ilmiöitä paremmin kuin perinteiset koneoppimisen menetelmät (Kananen & Puolitaival, 2019). Syväoppimisen suosio kasvoi erityisesti 2010-luvulla, jolloin suurten teknologiayritysten tuottamat massiiviset datamäärät ja laskentatehon kasvu mahdollistivat neuroverkkojen tehokkaan kouluttamisen (Deep learning, 2025).

Syväoppiminen eroaa perinteisestä ohjatusta ja ohjaamattomasta oppimisesta siinä, että se kykenee hyödyntämään datasta abstrakteja ja useampitasoisia piirteitä ilman käsin määriteltyjä sääntöjä. Tätä ominaisuutta hyödynnetään esimerkiksi autonomisissa ajoneuvoissa, konenäössä tai roboteissa, joissa järjestelmän on jatkuvasti sopeuduttava muuttuviin tilanteisiin ja opittava reaaliaikaisesti sensoreiden tuottamasta datasta (Merilehto, 2018).

Keinotekoiset neuroverkot (Artificial Neural Network, ANN) muistuttavat rakenteellisesti ihmisaivojen hermosolujen toimintaa, jotka näkyvät kuviossa 2. Neuroverkko koostuu neuroneista, eli laskentayksiköistä, jotka vastaanottavat syöteittä, käsittelevät niitä ja välittävät eteenpäin seuraaville neuroneille. Tyypillinen neuroverkko koostuu: sisääntulokerroksesta, joka vastaanota datan, piilokerroksista, jotka varsinaisesti tuottavat laskennan sekä ulostulokerroksesta, joka tuottaa lopullisen ennusteen tai luokituksen. (Kananen & Puolitaival, 2019)

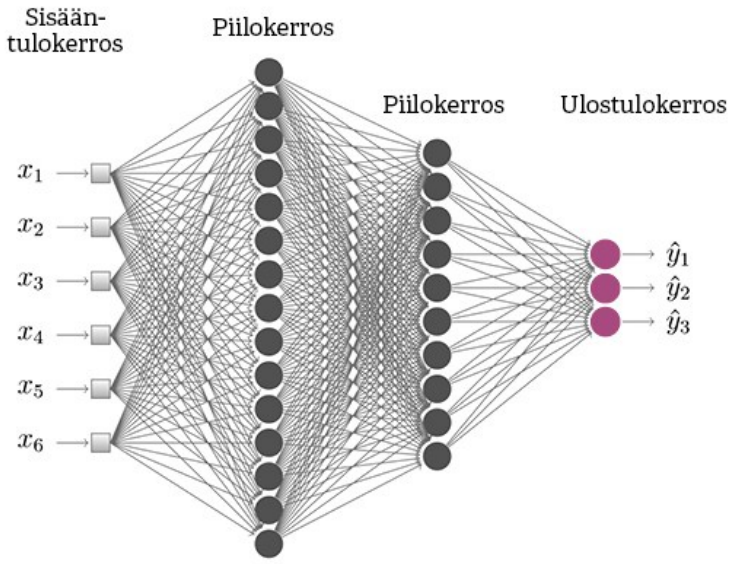

Kuvio 2 Neuroverkkojen rakenne (Merilehto, 2018)

Yksittäisen neuronin toiminta perustuu yksinkertaiseen päättelyyn: neuroni saa syötteen, painottaa sen määriteltyjen painokertoimien perusteella ja aktivoi itsensä, mikäli syöte ylittää aktivaatiokynnyksen. Aktivaatio voidaan tulkita joko ”kyllä” tai ”ei” -päätöksenä, tai jatkuvana arvona riippuen käytetystä aktivointifunktiosta (Kananen & Puolitaival, 2019).

Neuronien väliset yhteyden muodostuvat painokertoimista englanniksi ”weights”, jotka säätelevät sitä, kuinka voimakkaasti yhden neuronin tuottama signaali vaikuttaa toisen neuronin toimintaan. Esimerkiksi, jos syväverkoston neuronin painokerroksen arvo on $x>0.5$, se vahvistaa vaikutusta, ja jos painokerroin on $x<0.5$ se vaikuttaa heikosti. Puolestaan jos painokerroin on negatiivinen, se kääntää syötteen vaikutuksen vastakkaiseksi. Painokertoimen säätäminen on syväoppimisen ydin. Neuronien arvot optimoidaan koulutusvaiheessa siten, että verkko kykenee tuottamaan mahdollisimman oikeita ennusteita.

Tekoälyjärjestelmät, jotka perustuvat syväoppimiseen eivät vaadi manuaalisesti rakennettuja piirteitä vaan pystyvät käsittelemään raakadataa suoraan lähdestä. Lähteenä sisäisessä logistiikassa yleensä toimii konenäkö, NLP sekä IoT-laiteisto.

4 Tekoälyn integrointi sisäiseen logistiikkaan

Integroimalla tekoälyjärjestelmän sisäisen logistiikkaan pyritään ensisijaisesti tehostamaan prosesseja sekä parantaa ulostulon nopeutta, tarkkuutta sekä riskien ennustamista. Tavoitteena on tekoälyn integrointi olemassa olevaan yritys ympäristöön ilman globaali muutoksia ja muodostaa toimintaa yritys ohjelmiston sekä prosessien parissa.

Integroitu tekoälykokonaisuus toimii osana jokaista sisälogistiikan prosessia ja täydentää jatkuvasti ihmisten, automaation ja ohjelmiston toimintaa. Laajemmin tarkisteltuna tekoälyllä on keskeinen rooli hallintojärjestelmissä, joissa se tukee data analysointia, ennustamista ja riskien hallintaa. Datan analysointi, ennustaminen sekä riskien hallintaa tulee toimimaan tekoälyn päätehtävänä.

Kokonaisuusjärjestelmä kytkeytyy ERP-ohjelmistoon, jonka tekoälyn päätöksentekoa vahvistaa Lean-ajattelu ja ISO-standardit. Näiden viitekehysten avulla voidaan varmistaa, että organisaation toiminta pysyy johdonmukaisena, tehokkaana ja laadukkaana myös tekoälyn ohjaamana.

4.1 Tekoälyn sähköinen integrointi sisäiseen logistiikkaan

Tekoälyn integrointi sisälogistikaan ympäristöön ja yrityksen ohjelmistoon sähköisellä tasolla edellyttää huolellista ennakkoon suunnittelua. Kuten kappaleessa 3 on todettu tekoäly järjestelmät koostuvat algoritmeista, jotka määrittävät toimintaa, koneoppimisisesta, joka mahdollistaa oppimisen sekä laajasta määrästä dataa, jonka avulla tekoäly oppii.

Tekoäly voi toimia joko täysin itsenäisesti tai toiminnoissa, jotka tukevat kevyemmät koneoppimismenetelmät. Itsenäistä päätöksentekoa edellyttävät tehtävät vaativat tyypillisesti syväoppimiseen perustuvia neuroverkkoja, kun taas kevyempiin prosesseihin

riittää ohjattu koneoppiminen, kuten poikkeamien tunnistus tuodussa datassa tai materiaali kysynnän ennustaminen. Esimerkiksi, XGBoost mallien avulla (Chen & Guestrin, 2016).

Nykyiset sisälogistiikan integroituvat tekoälyjärjestelmät, poikkeuksetta perustuvat ANI pohjaiseen tekoälyjärjestelmiin. ANI-järjestelmät on suunniteltu suorittamaan rajatuista, ennalta määrittelyistä tehtävistä, ja niiden etuna on tarkkuus sekä prosessien ruuhkien ja virheiden vähentäminen (Kananen & Puolitaival, 2019). Yleisesti on käytössä kolme ML eli koneoppimismallia muotoa ohjattu, ohjaamaton sekä syväoppiminen. Harvinaisemmat menetelmät, kuten puolivalvottu ja vahvistusoppiminen, soveltuvat tilanteisiin, joissa yritys rakentaa kokonaisvaltaisen tekoälyjärjestelmän.

Esimerkiksi, ennustettavan varaston täydennysjärjestelmän tapauksessa algoritmi perustuu laskentamalleihin, jotka ohjaavat tekoälyn päätöksentekoa. Algoritmia seuraa sopivan koneoppimistavan valinta. Lineaarisen ja valmiiksi suodatun dataan, soveltuu ohjattu oppiminen, puolestaan monimutkaisemmat ja itsenäiset tehtävät vaativat syväoppimista. Syväoppiminen on tehokas esimerkiksi kuvanäössä sekä varaston automatisoinnissa dynaamisessa ympäristössä (Fraunhofer IML, 2023).

Ohjattu oppiminen soveltuu erityisen hyvin ennustamiseen, luokitteluun sekä perusoptimointiin. Sitä voidaan hyödyntää esimerkiksi materiaalin ylläpidossa, varaston täydennyksessä ja tilausmäärien ennustamisessa. Hyötyä siitä voi olla myös datan analysoinnissa sekä poikkeamien tunnistamisessa. Lisäksi ohjattua oppimista voidaan soveltaa rutiinitehtävien optimointiin, kuten työvoiman tarpeen ennustamiseen tai WMS- ja ERP järjestelmien pick-list ja keräilyohjeiden muodostamiseen. (Wurll, 2022)
Ohjaamaton oppiminen eli UL soveltuu tilanteisiin, joissa datan muoto ei ole lineaarista eikä valmiiksi luokitettua tai suodatettua. Ohjaamattoman oppimisen tavoitteena on tunnistaa datasta poikkeamia, rakenteita ja yhtäläisyyksiä. UL:ää voidaan hyödyntää esimerkiksi varaston layoutin optimoinnissa, epänormaalien tapahtumien tunnistamisessa sekä AGV/AMR- robottien liikkeiden klusteroinnissa. (Wurll, 2022)

Syväoppiminen eli DL, edustaa ANI ylintä tasoa. Organisaatio implementoinnissa DL vaati huomattavasi enemmän laskentatehoa, mitä toteutetaan GPU (Graphics Processor Unit) avulla. Lisäksi myös suuria datamääriä ja enemmän kehitystyötä. DL puolestaan tarjoaa vastineeksi korkeamman tarkkuuden, oppimiskyvyn ja skaalaavuuden. DL sopii dynaamisesti muuttuviin ympäristöihin, erityisesti konenäköön, optimointiin sekä autonomisten robottijärjestelmien ohjaukseen.

Konenäön integroinnilla sisälogistiikkaan pyritään vähentämään ruuhkia, nopeuttamaan prosesseja, pienentämään virhemääriä sekä tietokantojen reaaliaikaisen päivittämiseen. Konenäkö perustuu kuvan pikselitason tulkintaan. Konenäkö perustuu CNN eli Convolutional Neural Network teknologiaan, joka toimii kuvien tunnistuksen ytimenä (Goodfellow, 2016). CNN hajottaa kuvan osiin, tunnistaa materiaalin piirteet, kuten koot, muodot, viivakoodit, QR-koodit ja RFID-tunnisteet, sekä tunnistaa laatupoikkeamia. Tämän jälkeen kuvan kokoa tiivistetään “pooling”-menetelmällä laskennan tehostamiseksi ja muistikuorman keventämiseksi. CNN:n ja “pooling” kerrosten tuottamat arvot ohjaavat lopullista päätöksentekoa (Boureau, 2010).

Konenäkö ei ainoastaan tunnistaa materiaalia, vaan voi automatisoida kokonaisia prosesseja. Esimerkiksi järjestelmä voi suorittaa automaattisia hyllyskannauksia, tunnistaa tyhjät varastopaikat, laskea varastosaldoja, suorittaa laatutarkastuksia sekä tunnistaa lavatyyppejä ja vaurioita.

Syväoppiminen parantaa myös AGV/AMR robottien toimintaa. Robottien päätöksenteko perustuu sensori ja anturiteknologiaan kuten CNN, LiDAR, UWB/BLE, IMU sekä IR (Bahga & Madisetti, 2014). Sen lisäksi myös syväoppimisen menetelmiin kuten RNN, RL sekä SFN malleihin, jotka mahdollistavat autonomisen liikkumisen dynaamisesti muuttuvassa ympäristössä.

4.2 Tekoälyn integrointi sisälogistiikan ohjelmistoon

Sisäisen logistiikan ympäristö perustuu jatkuvaan kommunikointiin, ennustamiseen, laatutarkistukseen sekä ajan ja riskien hallintaan. Näistä syistä kriittisin osa tekoälyn onnistuneessa integroinnissa on reaaliaikainen, läpinäkyvä ja luotettava tiedonvaihto järjestelmien välillä. Päärooli on ERP järjestelmällä. ERP järjestelmä toimii organisaation taloudellisena ja operatiivisena ytimenä. ERP-järjestelmä tuottaa perustiedon, jonka varaan tekoälypohjaiset optimointiratkaisut rakennetaan (Wurll, 2022).

WMS järjestelmä puolestaan toimii sisälogistiikan operatiivisena moottorina. WMS toiminta voidaan tehostaa ML tai heurististen tekomallien avulla. ML-menetelmiä voidaan parhaiten hyödyntää esimerkiksi historiallisen tilausdatan analysoinnissa, jolloin WMS kykenee ennustamaan tilausten määrä, optimoimaan varaston täydennystarpeita sekä itsenäisesti suorittaa täydennyksiä. Tekoälyn hyödyntäminen WMS ympäristössä mahdollista opettamista myös varastopaikojen optimaalista käyttöä mikä puolestaan vähentää keräilymatkoja ja nopeuttaa läpimenoaikoja.

Keräilyreittien optimointi voidaan toteuttaa graafiteorian tai simuloinnin ja vahvistusoppimisen (reinforcement learning, RL) avulla. Simulaatiossa mallinnetaan solmuista ja reiteistä koostuvan kartoituksen. Algoritmit kuten esimerkiksi Dijksra ja A* (Dijkstra, 1959), tukevat reittisuunnittelua. RL puolestaan mahdollistaa dynaamisen reittien mukauttamisen reaaliaikaisten tilanteiden perusteella. Lisäksi integroitu AI WMS järjestelmään, voi arvioida ympäristön kapasiteetin kuormitusta, työjonojen kasvua ja mahdollisten resurssitarvetta. Lisäksi tämän mahdollista ML pohjaisten tilannearviointi tai DL pohjaisen visuaalisen seurannan.

MES eli Manufacturing Execution System, yhdistää ERP järjestelmän ja lattiatason operaatioiden välillä. MES vastaanottaa tuotantosuunnitelmat ERP:ltä ja pilkkoo ne konkreettisiksi vaiheiksi. MES järjestelmä osaa autonomisesti suorittaa tehtäviä kuten, materiaalin hakukomento WMS-järjestelmästä, koneiden käynnistys tuotantotehtävien

mukaisesti, tuotannon etenemisen seuranta koneiden tuottaman datan perustella sekä laaduntarkistus IoT-avulla.

Lisäksi MES järjestelmän keskeinen vahvuus on kyky ohjata tuotantoa reaaliajassa. Järjestelmä voi välittömästi hälyttää materiaalipuutteista, koneiden seisokeista tai laatuvaihteluista. MES jatkuvasti kerää dataa tuotantoprosessien eri vaiheista, kuten valmistusmääristä, työajoista, hävikistä, laatuvirheistä sekä OEE-arvoista. Tämä dataa kiertää jatkuvasti ERP:lle, WMS:lle, IoT-laiteistolle, sekä robotiikkajärjestelmille. Mikä puolestaan mahdollista kokonaisvaltaisen prosessihallinnan.

Tekoälyn integraation MES ympäristöön on mahdollista toteuttaa kahdella tavalla. Kevyessä integraatiossa ML mallit suorittavat datan esikäsittelyä, luokittelua ja tukevat päätöksentekoa. Syvemmässä integraatiossa hyödynnetään DL malleja, jotka puolestaan voidaan hyödyntää kuvapohjaiseen laadunvalvontaan sekä RL malleja tilanteissa, joissa päätöksiä on tehtävä reaaliajassa ja dynaamisissa olosuhteissa.

Tekoälyn hyödyntämisessä on jatkuvat datavirrat ja datan laadukas esikäsittely on ratkaisevassa asemassa. Kuten aikaisemmin todettiin, suurin osa datasta poimitaan MES-järjestelmästä. MES-järjestelmässä hyödynnetään ETL- (Extract, Transform, Load) sekä ELT- malleja (Extract, Load, Transform). Menetelmien ero on prosessien järjestyksessä. ETL-malleissa data poimitaan, muokataan ja sen jälkeen ladataan tekoälyjärjestelmään. ELT-malleissa puolestaan ensin ladataan kohdejärjestelmään, jossa se muokataan myöhemmin. Molemmat menetelmät mahdollistavat tekoälymallien oppimisen sekä reaaliaikaisen tai ennakoivan päätöksenteko.

4.3 Fyysinen integrointi

Sähköistä tekoälyintegraatiota täydentää myös fyysiset laitteistot. Fyysiset laiteistot toimivat tekoälyn ”aisteina” ja mahdollistavat järjestelmien reagoinnin ympäristöön. Vastaanottopisteissä konenäkö tarvitse korkearesoluutioisia kameroita materiaalin tarkkaan tunnistamiseen. Mitä suurempi pikselimäärä kamerassa on, sitä

yksinkohtaisempaa dataa voidaan tuottaa ja hyödyntää analytiikassa. Esimerkiksi 4 tai 8K-kameroilla tuotettu kuva voidaan analysoinnin jälkeen supistaa “pooling”-menetelmällä. “Pooling” menetelmässä säilytetään vain olennaisimmat piirteet ja pienennetään laskennan ja muistin tarvetta. Puolestaan tunnistamisprosessi perustuu tyypillisesti CNN, jotka suodattavat kuvasta oleelliset rakenteet ja ominaisuudet, kuten viivakoodit, QR-tunnisteet, RFID merkinnät tai poikkeamat laadussa (Boureau, 2010).

Tekoäly tarjoaa sisälogistiikassa myös fyysistä tukea autonomisten kuljetusjärjestelmien kautta. AGV- ja AMR robotit suorittavat materiaalin siirrot ja hyllytykset varastoalueella. Näiden robotteihin integroitujen järjestelmien toimintaa perustuu useasti syväoppimiseen (DL) ja vahvistusoppimiseen (RL), sillä robottien on toimittava dynaamisissa ja muuttuvissa ympäristöissä. Päätöksenteon on oltava reaaliaikaista, erityisesti tilanteissa, joissa robotin on valittava optimaalisin reitti, vältettävä esteet ja sopeuduttava työkuorman vaihteluun (Turlapati, 2021).

Fyysisen järjestelmä tukevat myös RFID-, QR- ja IoT-pohjaiset sensorijärjestelmät, jotka seuraavat materiaalin sijaintia jatkuvasti. IoT-sensorit voivat puolestaan tunnistaa esimerkiksi varastosaldoja, liikevirtoja tai poikkeamia ympäristössä. Kun sensorit tuottavat jatkuvaa reaaliaikaista dataa, tekoäly voi hyödyntää tätä analysoinnissa sekä optimoinnissa sekä päätöksenteossa ja riskienhallinnassa. Datavirran kasvaessa tekoälyn analytiikan tarkkuus paranee, ja sen kyky havaita poikkeamia vahvistuu.

Yksinkertaisemmissa sisälogistiikkaympäristöissä fyysinen integraatio voi toteutua kevyempien automaatioratkaisujen avulla. Esimerkiksi kappaleessa 2.4 mainitut hihna- ja rullajärjestelmät voidaan varustaa myös IoT-sensoreilla ja CNN konenäöllä. Niiden avulla järjestelmä itsenäisesti lajittelee ja ohjaa tavaroita automaattisesti oikeille paikoille. Tämä teknologiataso on yleinen lentokenttien matkatavarahihnastoissa ja suurissa jakelukeskuksissa.

4.4 Standardien vaikutus

Kuten kappaleessa 3 todettiin, tekoälyjärjestelmät perustuvat algoritmeihin ja koneoppimisen rakenteisiin. Niiden oppiminen ja päätöksenteko edellyttävät jatkuvia datavirtoja. Tämän vuoksi on tärkeä määrittää jo kehityksen alkuvaiheessa ne periaatteet, arvot ja standardit, joiden mukaisesti tekoäly toimii ja tekee päätöksiä. Näitä periaatteita ohjaavat sekä organisaation sisäiset tavoitteet, että kansainväliset laatu ja turvallisuus standardit.

Nykyaikaista tekoälyn kehitystä laadunhallinnassa kuvaa Quality Management 4.0 (QM 4.0) (Nguyen, 2023). QM 4.0 edustaa nykyaikaista dataohjautuva ja ennakoivaa laadunhallintajärjestelmää. Toisin kuin edeltävä QM 3.0, joka keskittyi pääasiassa virheiden havaitsemiseen ja tilastollisen prosessi ohjaukseen. QM 4.0 integroi digitaalista teknologia kuten tekoälyn, IoT-järjestelmät ja reaaliaikaisen datan osaksi koko arvoketjua.

Yksi QM 4.0 tärkeimmistä muutoksista on siirtyminen reaktiivisesta laadusta ennakoivaan laatuun. IoT-laiteisto ja sensorit keräävät dataa reaaliaikaisesti tuotannosta ja sisälogistiikan prosesseista. Tämän perustella koneoppimismallit tunnistavat poikkeamia ja varhaisia merkkejä mahdollisesta prosessin heikentymisestä. Tämä puolestaan mahdollista virheiden ehkäisyn ennakkoon.

QM 4.0 viite kehitys tukee Lean- ja Six Sigma menetelmiä sekä kansainvälisiä ISO-standardeja. Sisälogistiikan kehittäminen vaatii sekä prosessitehokkuutta, minkä tarjoaa Lean-menetelmät, että varianssin ja laadunvarmistusta, mitä tukee Six Sigma. Näitä menetelmiä voidaan hyödyntää yhdessä tekoälyn päätöksentekojärjestelmän kanssa. Tämän seurauksena syntyy kokonaisuus, joka sekä tehostaa että vähentää mahdollisia virheitä.

Nykyaikainen Lean 4.0 keskittyy hukan poiston, materiaalivirran tehostamiseen ja prosessien sujuvuuteen. Sisälogistiikassa tämä tarkoittaa muun muassa ylimääräisten

liikkeiden poistoa ja varastotilan tehokampaa käyttöä. Tekoälyä hyödyntämällä voidaan automatisoida esimerkiksi AGV/AMR-robottien keräilyreittien optimointia, tilausten yhdistämistä, raaka-aineiden puskurointia sekä keräilyjärjestyksen suunnittelua. Tämän ansiosta läpimenoaika lyhenee ja virheiden määrä vähenee (Pongboonchai-Empl, 2024).

Six Sigma 4.0 täydentää Lean-lähestymistapaa keskittymällä enemmän virheiden minimointiin ja prosessivaihteluun. Sisälogistiikan ympäristössä tämä viittaa pakkausvirheiden vähentämiseen, keräilyn oikeellisuuden varmistamiseen sekä tarkempien kysyntäennusteiden muodostamiseen. Tekoälyllä varustettu Six Sigma-menetelmä mahdollista konenäköjärjestelmien reaaliaikaisen laadunvalvonnan, jossa poikkeamat havaitaan välittömästi ja reagoidaan automaattisesti. Tavoitteena on lähes virheetön prosessisuorituskyky (Pongboonchai-Empl, 2024).

4.5 ISO-standardit

Teknisten elementtien lisäksi tekoälyn toimintaa määrittävät myös kansainväliset standardit. Standardit puolestaan varmistavat, että järjestelmät ovat turvallisia, laadukkaita ja auditoitavissa. Sisälogistiikan ympäristössä ISO-standardit muodostavat perustan yritys toiminnan yhtenäistämiselle, laadun varmistamiselle ja turvallisuuden ylläpitämiselle. (International Organization for Standardization [ISO], n.d.)

Kehittyneissä tekoälyjärjestelmissä hyödynnetään useita standardeja, kuten ISO 9001:2015, ISO/IEC 42001:2023, ISO 13053, ISO 18404, ISO/IEC 27001, ISO 22400, ISO 45001, ISO 50001 sekä ISO 14001. Jokainen näistä ohjaa tekoälyä ja logistiikkaprosesseja eri näkökulmista.

ISO 9001 toimii koko järjestelmän laadunhallinnallisena perustana. Se määristä periaatteet alusta asti prosessiajattelulle. Sen lisäksi myös rikiperusteiselle johtamiselle ja jatkuvalle parantamiselle. Tekoälyn integroinnissa ISO 9001 varmistaa, että

datankeruu, algoritmien toiminta, IoT-järjestelmät ja ohjelmistorajapinnat ovat johdonmukaisia.

Tekoälyn kannalta merkittävin standardi on ISO/IEC 42001, joka on maailman ensimmäinen tekoälyn hallintajärjestelmän standardi. Se määrittää, miten yrityksen tulee hallita tekoälykehitystä, riskejä, eettisiä periaatteita, suorituskykyä ja tietoturvaa. Lisäksi ISO42001 luo perustan myös tekoälyjärjestelmien turvalliselle ja vastuulliselle käytölle niin fyysisissä sovelluksissa kuten esimerkiksi konenäkö, AGV ja AMR roboteille, kuin myös ohjelmistoympäristölle kuten data-analytiikalle ja ennustemalleille. ISO 42001 korostaa mallien seurantaan ja virheiden ehkäisyä.

Myös Lean Six Sigman toimintaa perustuu standardeihin. ISO 13053 ja ISO 18404 ohjaavat prosessien tilastollista analyysia ja ammattilaisten osaamisvaatimuksia. ISO 13053 keskittyy DMAIC- prosessiin ja dataperustaiseen prosessianalyysin. ISO18404 puolestaan määrittele Lean- ja Six Sigman osaamistasot. ISO 13053 ja 18404 standardien soveltaminen ennen tekoälyn integrointia varmistaa, että logistiikan prosessit ovat jo lähtökohtaisesti optimoituja ja stabiileja. Tämä on välttämätöntä koneoppimisen luotettavuudelle.

Koska sisälogistiikan prosessien ohjaus perustuu vahvasti digitaalisiin järjestelmiin, ISO/IEC 27001- tietoturvastandardi on erityisen tärkeä. Se määrittää vaatimukset datan suojaukselle ja tietojärjestelmien turvallisuudelle. Tekoälyjärjestelmien yhteydessä standardi suojaa muun muassa IoT-laiteiston tuottamaa dataa, ohjelmiston kuten ERP/WMS/MES tietoja, API (Application Programming Interface) ja pilvipalvelin yhteyksiä sekä AGV ja AMR robottien ohjauskanavia. Koska tekoälyn toimintaa perustuu laajoihin datamassoihin, jotka voivat sisältää yrityksen arkaluonteista tietoa, tietoturvaan liittyvät riskit ovat merkittäviä.

Standartit kuten ISO 22400, ISO 45001, ISO 50001 ja ISO 14001 eivät suoraan ohjaa tekoälyjärjestelmien toimintaa. Standartit puolestaan tukevat tekoälyn hyödyntämistä sisälogistiikan kokonaisympäristössä.

ISO2400 määrittelee tuotannon ja logistiikan suorituskykymittarit, kuten OEE:n, läpimenoajat, WIP ja JIT. Tämä on erityisen tärkeää MES-järjestelmille, koska MES järjestelmä hyödyntää näitä mittareita päätöksenteon tukena.

ISO 45001 ohjaa työterveyttä ja työturvallisuutta fyysisessä ympäristössä. Tekoälyä hyödyntävissä ympäristössä ja järjestelmissä tämä tarkoittaa esimerkiksi konenäön turva-alueiden tunnistamia, AGV ja AMR robottien liikennesääntöjä, törmäysriskien hallintaa sekä automaattisten nostolaitteiden valvontaa. Standardi tukee autonomisten järjestelmien turvallista käyttöä ja työntekijöiden suojelua.

Yritykset jatkuvasti pyrkivät yhä useammin energiatehokuutteen ja ympäristöystävällisiin tuloksiin. ISO 5001 ja ISO 14001 standardit toimivat tärkeänä tukena energiatehokuudessa ja ympäristöystävällisyydessä. ISO 50001 ohjaa energianhallintaa, ja sen yhdistäminen tekoälyyn mahdollistaa esimerkiksi robottien lataus ja käyttösyklien optimoinnin sekä materiaalivirtojen reitityksen energiatehokuuden perusteella. ISO 14001 puolestaan keskittyy ympäristöjärjestelmiin ja varmistaa, että logistiikan prosessit ja tekoälyyn perustuvat ratkaisut tukevat kestävää kehitystä.

4.6 Tekoälyn vaikutukset sisälogistiikan tehokkuuteen

Tekoälyn integroituminen sisäisen logistiikan ympäristöön muuttaa perinteiset varasto- ja materiaalinkäsittelyprosessit ennakoivaksi, turvallisemmiksi ja vähemmän virhealttiksi. Yritykset toimivat erilaisissa ympäristössä ja niiden tarpeet vaihtelevat yritystoiminnan mukaisesti, joten tarkkoja arvoja on vaikea määrittää. Kansainväliset tutkimukset, kuten Deloitte ja Mckinsey (Johansen, 2025) keskittyvätkin suorituskykymittareihin, jotka kuvaavat riskien hallintaa, toimintavarmuutta, materiaalivirtoja, läpimenoaikoja sekä organisaation kehitysmahdollisuutta.

Yrityksien kehitys vaatii nykyaikaisia ratkaisuja ja kuten kappaleessa 4.4 on mainittu QM 4.0 on keskeinen lähestymistapa. Se ei ainoastaan määrittele uusia standardeja vaan myös mahdollistaa prosessien tehostamisen, analysoinnin ja automaattisen ohjauksen aiempaa taloudellisemmin ja tarkemmin. Tekoäly on keskeinen osa nykyistä digitalisaatiota, ja sen varhainen implementointi tarjoa merkittävän kilpaedun markkinoilla. Tekoälyn käyttöönotto muokkaa myös yrityksen ohjelmistoinfrastruktuuria ja ympäristöä. Ohjelmistoinfrastruktuurit kuten ERP WMS MES järjestelmät sekä API, data pipeline, IoT-sensorit ja MQTT välitykset muodostavat digitaalisen ekosysteemin, jossa tieto liikkuu reaaliaikaisesti ja mahdollistaa tekoälypohjoisen päätöksenteon. Tämä puolestaan tukee myös fyysisiä toimintoja, kuten konenäköjärjestelmiä sekä AGV/AMR-robotteja.

McKinseyn ja Deloitten tutkimukset osoittavat, että varhaiset tekoälyn hyödyntäjät saavuttavat keskimäärin jopa 15 % pienemmät logistiikkakustannukset, 35 % paremman varastonhallinnan ja 65 % korkeammat palvelutasot verrattuna kilpailijoihin (Johansen, 2025).

4.6.1 ERP ja tekoäly

ERP-järjestelmän ja tekoälyn yhdistäminen muuttaa tiedonhallintajärjestelmän ennakoivaksi ja analysoivaksi työkaluksi. Tekoälypohjainen ERP analysoi historiallista dataa, markkinatrendejä ja ulkoisia signaaleja tuottaen tarkkoja ennusteita ja tukien optimointipäätöksiä.

Deloitten (2024) vuoden 2024 raportoinnin mukaan 53 % yrityksistä on parantanut toimitusketjunsa suorituskykyä tekoälyn integroinnin avulla sekä 68 % hyödyntää data-analytiikkaa toimintojen optimointiin. ERP tehostus tuo lisäksi uusia mahdollisuuksia toimintaympäristöön, kuten reaaliaikaisen näkyvyyden sekä automaattiset täydennystilausten ennusteet (Johansen, 2025).

4.6.2 WMS ja tekoäly

Tekoälyn integrointi WMS-järjestelmään tuo merkittäviä tehokkuusparannuksia varaston operatiiviseen toiminaan. Tutkimuksen mukaisesti AI-WMS integraation avulla liikkumisaika vähenee 25 %, puutelistojen määrä pienenee 30 % ja operatiiviset kustannukset laskevat 15 %.

MIT:n ja Mecaluxin vuoden 2025 tutkimukset osoittavat, että 60 % varastoista hyödyntävät tekoälyä päivittäisissä prosesseissa, kuten keräilyssä, varastonhallinnassa, huollossa, työvoiman suunnittelussa sekä turvallisuudessa. AI:lla varustettu WMS sovellus myös lyhentää merkittävästi keräilyaikaa, vähentää poimintavirheet 90 % sekä lisää varastokapasiteettiä 7–15 % ja suorittaa automaattisen täydennyksen ennustemallien perusteella (AJOT, 2025).

4.6.3 MES ja tekoäly

MES järjestelmä puolestaan hyödyntää tekoälyä reaaliaikaisen tuotannon ohjauksen luomisessa ja kytkevät lattiatason toiminnan yrityksen liiketoimintatavoitteisiin. Tutkimukset osoittavat, että tekoälyn integrointi MES-järjestelmään voi parantaa tuotannon tehokkuutta 25 % vähentää odottamattomia tuotannon pysähdyksiä 50 % ennakoivan huollon tarpeen avulla ja pidentää laitteiden toimintaikää n. 20 %. Tässä ympäristössä MES valvoo tuotantoa konenäöllä, optimoi aikatauluja ja reagoi välittömästi poikkeamiin. Samalla se on jatkuvassa yhteystyössä muden ohjelmistojen ja laitteiden kanssa.

4.6.4 AGV/AMR-robotit

Hyperautomaatio strategiaan täydentää autonomiset logistiikkarobotit. Tutkimuksen mukaisesti vuonna 2024 78 % varastoista oli ottanut käyttöön vähintään yhden autonomisen järjestelmän, 67 % uusista AMR roboteista sisältää dynaamisen reittisuunnittelun tekoälyn avulla, 42 % kaikista AMR-asennuksista ovat

verkkokauppavarastoissa ja tuloksena robotit keskimäärin lyhensivät keräilyaikaa 34 % (Market Growth Reports, 2025).

4.6.5 Konenäkö

Konenäön integrointi vastaanottoon ja laadunvalvontaan mullistaa perinteisen prosessit. Uudistuneen konenäön avulla saamme yli 90 % parannuksen virheiden tunnistustarkuudessa sekä yli 90 % työvoimakustannusten vähenemisen manuaalisiin tarkistuksiin verrattuna. Gartner ennustaa, että vuoteen 2025 mennessä yli 50 % valmistajista hyödyntää tekoälyä laadunvalvonnassa mikä vähentää virheitä noin 30 %. Google Cloud puolestaan raportoi että 39 % valmistajista käyttää tekoälyä laatutarkistuksessa ja 35 % tuotantolinjan valvonnassa (Johansen, 2025).

4.6.6 Standardit

Standardien integrointi tekoälyjärjestelmiin on osoittanut tehokkaan parantamiseen. Tutkimusten mukaisesti 77 % organisaatioista kehittää tekoäly hallinnan sekä vain 12 % on implementoinut täyden hallintajärjestelmän.

5 Yhteenveto

Tämän tutkielman tavoitteena oli selvittää, miten tekoälyn integraatio sisäiseen logistiikkaan voidaan toteuttaa ja millaisia hyötyjä voidaan saavuttaa. Tutkielmassa pyrittiin erityisesti osoittamaan, että tekoälyratkaisujen käyttöönotto on mahdollista ilman laajoja infrastruktuurimuutoksia. Mitä se todellisuudessa vaatii, on olemassa olevan ohjelmistoarkkitehtuurin sekä kypsän prosessikartoituksen. Lisäksi tavoitteena oli tuoda esiin, miten digitalisaatio ja tekoäly vahvistavat organisaatioiden tehokkuutta ja kilpailukykyä nykypäivän globaaleilla markkinoilla.

Tulokset osoittivat, että sisäisen logistiikan ohjelmistokerros toimii operatiivisena selkärankana. Vaikka prosessit jakautuvat järjestelmien kesken, jokainen järjestelmä suorittaa sille määritellyt tehtävät tarkasti ja ennakoitavasti. Tekoälyn onnistunut hyödyntäminen edellyttää kuitenkin, että prosessit on mallinnettu, optimoitu ja vakioitu ennen integraatiota. Vasta tällöin tekoäly pystyy toimimaan saumattomasti.

Tutkielma osoittaa myös, että tekoälyjärjestelmät ovat luonteeltaan tehtäväkohtaisia. Järjestelmä, joka on suunniteltu esimerkiksi konenäköä varten, ei ole siirrettävissä analytiikka- tai robottipohjaiseen ohjaukseen. Tämä johtuu siitä, että jokaiseen tekoälysysteemiin rakennetaan oma algoritmi. Tämä koskee myös oppimismenetelmä, olipa kyseessä ohjattu, ohjaamaton tai syväoppiminen. Koska malli oppii täsmällisesti sille annetusta datasta, malli ei kykene yleistävään suorituskykyyn toisessa tehtävässä ilman uudelleenkoulutusta.

Tutkielman perusteella voidaan todeta, että tekoäly integroinnilla sisäiseen logistiikkaan on merkittävä potentiaali tehostaa sekä operatiivisia että strategisia prosesseja. Hyödyt näkyvät erityisesti virheiden vähenemisenä, lyhyempinä läpimeno aikoina ja paremman päätöksenteon mahdollistamisena. Onnistunut integraatio edellyttää kuitenkin laadukasta ja yhtenäistä dataa, standardisoitua prosessirakennetta, sekä teknologioiden hallittua ja vaiheittaista käyttöönottoa. Näiden edellytysten täyttyessä, tekoäly toimii

vahvana suorituskyvyn parantajana ja mahdollistaa sisäisen logistiikan kauaskantoista kehittymistä.

Lähteet

AJOT. (2025, 27. marraskuuta). *New MIT–Mecalux study finds AI now embedded in 60% of warehouses, reshaping productivity and workforce models*. American Journal of Transportation.https://www.ajot.com/news/new-mitmecalux-study-finds-ai-now-embedded-in-60-of-warehouses-reshaping-productivity-and-workforce-models

Aligni. (n.d.). *How ERP and MRP can work together*. Noudettu 5.12.2025, osoitteesta https://www.aligni.com/aligni-knowledge-center/how-erp-and-mrp-can-work-together/

Bahga, A., & Madisetti, V. (2014). *Internet of Things: A hands-on approach*. Universities Press.

Boureau, Y., Ponce, J., & LeCun, Y. (2010). *A theoretical analysis of feature pooling in vision algorithms*. In *Proceedings of the 27th International Conference on Machine Learning (ICML)* (pp. 111–118). https://yann.lecun.com/exdb/publis/pdf/boureau-icml-10.pdf

Buzinkay, M. (2025, 11. syyskuuta). *Internal logistics in manufacturing*. Identec Solutions. https://www.identecsolutions.com/news/internal-logistics-in-manufacturing

Canon, J., Santos, R. G. F., Carvalho, V. J. R., Monte, M. D. H., Barros, T. B. S., & Lima, L. (2025). Integrated logistics management through ERP system: A case study in an emerging regional market. Logistics, 9(2), 59. https://doi.org/10.3390/logistics9020059

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. Teoksessa *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (s. 785–794). ACM. https://doi.org/10.1145/2939672.2939785

Curcio, D., & Longo, F. (2010). Inventory and internal logistics management as critical factors affecting the supply chain performances. *International Journal of Simulation and Process Modelling, 5*(4), 300–312. https://doi.org/10.1504/IJSPM.2009.032593

Federal Highway Administration. (2005). *Logistics cost and discretionary cargo repositioning report*. U.S. Department of Transportation. https://ops.fhwa.dot.gov/freight/freight_analysis/econ_methods/lcdp_rep/index.htm

Fraunhofer Institute for Material Flow and Logistics IML. (2023). *Artificial intelligence in intralogistics: Potentials, algorithms, and applications*. Noudettu 13.12.2025, osoitteesta

https://www.iml.fraunhofer.de/en/fields_of_activity/artificial-intelligence-in-intralogistics.html

Grand View Research. (2025). *Warehouse management system market size, share & trends analysis report by component, by deployment (on-premise, cloud), by function, by application, by region, and segment forecasts, 2025 - 2030* (Report No. GVR-2-68038-151-1).https://www.grandviewresearch.com/industry-analysis/warehouse-management-system-wms-market

Hameed, H. M., Al Amry, K. A., & Rashid, A. T. (2019). The automatic storage and retrieval system: An overview. International Journal of Computer Applications, 177(16), 36–43. https://doi.org/10.5120/ijca2019919603

IBM. (n.d.). *IBM Heritage*. Retrieved December 13, 2025, from https://www.ibm.com/history

IBM. (n.d.). *What is enterprise resource planning (ERP)?* Noudettu 5.12.2025, osoitteesta https://www.ibm.com/think/topics/enterprise-resource-planning

International Organization for Standardization. (n.d.). Standards. Noudettu 13.12.2025, osoitteesta https://www.iso.org/standards.html

Johansen, M. (2025, 5. elokuuta). *Building resilient supply chains: How AI, automation, and emerging technologies are shaping the future of global trade*. Supply Chain Management Review https://www.scmr.com/article/building-resilient-supply-chains-how-ai-automation-and-emerging-technologies-are-shaping-the-future-of-global-trade

Kananen, H., & Puolitaival, H. (2019). *Tekoäly: Bisneksen uudet työkalut*. Alma Talent.

Keith, R., & Feil-Seifer, D. (2024). *Robotic automation in warehouses: A multi-disciplinary perspective*. arXiv. https://doi.org/10.48550/arXiv.2406.08333

Logistics Costs and U.S. Gross Domestic Product—FHWA Freight Management and Operations. (2025). Noudettu 5. joulukuuta 2025, osoitteesta https://ops.fhwa.dot.gov/freight/freight_analysis/econ_methods/lcdp_rep/index.htm

Logistiikan Maailma. (2025). *Logistiikan Maailma*. https://www.logistiikanmaailma.fi/logistiikka/logistiikka-ja-toimitusketju/sisalogistiikka/

Logiwa. (2025). *The complete guide to warehouse management systems*. Noudettu 5.12.2025, osoitteesta https://www.logiwa.com/complete-guide-to-warehouse-management-systems

Merilehto, A. (2018). Tekoäly: Matkaopas johtajalle. Alma Talent.

Nguyen, T. A. V., Nguyen, K. H., & Tucek, D. (2023). Total quality management 4.0 framework: Present and future. Management Systems in Production Engineering, 31(1), 58–65. https://doi.org/10.2478/mspe-2023-0007

Ojanperä, T. (2023). *Tekoälyn vallankumous: Käsikirja* [E-kirja]. Alma Talent.

Pongboonchai-Empl, T., Antony, J., Garza-Reyes, J. A., Komkowski, T., & Tortorella, G. L. (2024). Integration of Industry 4.0 technologies into Lean Six Sigma DMAIC: A systematic review. *Production Planning & Control*. https://doi.org/10.1080/09537287.2023.2205574

SAP SE. (2015). SAP S/4HANA – External FAQ. http://www.sapevents.edgesuite.net/s4hana/pdfs/SAPS4HANAExternalFAQ_May2015v3.pdf

SAP. (n.d.). *What is a warehouse management system (WMS)?* Noudettu 5.12.2025, osoitteesta https://www.sap.com/products/scm/extended-warehouse-management/what-is-a-wms.html

Smartlogistix. (n.d.). *The most commonly used software in intralogistics*. Noudettu 5.12.2025, osoitteesta https://www.smartlogistix.com/blog/most-used-intralogistics-software

Stryker, C., & Kavlakoglu, E. (n.d.). *What is artificial intelligence (AI)?* IBM. Noudettu 13.12.2025, osoitteesta https://www.ibm.com/think/topics/artificial-intelligence

Stufano, F. (2024, 19. tammikuuta). *Six factors to consider before automating warehouses*. Supply Chain Management Review. https://www.scmr.com/article/six-factors-automating-warehouses

Turlapati, V., Campion, G., & Saeedi, S. (2021). Advancements in autonomous mobile robotics for intralogistics: From AGVs to AMRs. *Robotics and Computer-Integrated Manufacturing*, *72*, 102162. https://doi.org/10.1016/j.rcim.2021.102162

University of Alberta. (2025). *Chinook project: Legacy*. Haettu 7.12.2025 osoitteesta https://webdocs.cs.ualberta.ca/~chinook/project/legacy.html

Winkler, H., & Zinsmeister, L. (2019). Trends in digitalization of intralogistics and the critical success factors of its implementation. *Brazilian Journal of Operations & Production Management, 16*(3), 537–549. https://doi.org/10.14488/BJOPM.2019.v16.n3.a14

Wurll, T., ym. (2022). *Artificial intelligence in intralogistics: Potentials, algorithms, and applications*. Fraunhofer Institute for Material Flow and Logistics IML.

Zyllem. (n.d.). *Barcodes, QR codes, and RFID in logistics: Harnessing technology for efficiency*. Noudettu 5.12.2025, osoitteesta https://zyllem.com/post/barcodes-qr-codes-and-rfid-in-logistics-harnessing-technology-for-efficiency/