

Koneoppimisen rooli toimitusketjun riskienhallinnassa

Toimitusketjujen johtamisen kandidaatintutkielma

Laatija:
Jesper von Schrowe

Ohjaaja:
KTT Sini Laari

28.4.2024
Turku

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

Kandidaatintutkielma

Oppiaine: Toimitusketjujen johtaminen

Tekijä(t): Jesperi von Schrowe

Otsikko: Koneoppimisen rooli toimitusketjun riskienhallinnassa

Ohjaaja(t): KTT Sini Laari

Sivumäärä: 37 sivua

Päivämäärä: 28.4.2024

Tutkielmassa tarkastellaan koneoppimisen soveltamista toimitusketjun riskienhallintaan. Tutkielmaa keskittyy tarkastelemaan, miten koneoppimisen menetelmät soveltuvat toimitusketjun riskienhallintaan, minkälaisia hyötyjä yritykset voivat tällä saavuttaa, sekä mitä haasteita tai rajoituksia koneoppimisen soveltamiseen liittyy toimitusketjun riskienhallinnassa.

Globalisaation ja markkinoiden nopeiden muutosten myötä toimitusketjujen monimutkaisuus ja riskit ovat kasvaneet. Tämän ilmiön myötä myös riskienhallinta on haastavampaa kuin aiemmin. Koneoppiminen tarjoaa uusia mahdollisuuksia datan tehokkaaseen hyödyntämiseen ja ennakoivien analyysien tuottamiseen, mikä voi auttaa yrityksiä lieventämään häiriöitä, parantamaan tehokkuutta ja päätöksen tekoa, sekä vahvistamaan toimitusketjun resilienssiä. Tämä on erityisen tärkeää nopeasti muuttuvassa liiketoimintaympäristössä.

Tutkielman pääasialliset tutkimuskysymykset ovat:

- 1) Miten koneoppimista voidaan hyödyntää toimitusketjun riskienhallinnassa?
- 2) Mitkä ovat koneoppimisen käytön haasteet ja rajoitukset toimitusketjun riskienhallinnassa?

Tutkielma osoittaa, että koneoppiminen tarjoaa merkittäviä hyötyjä toimitusketjun riskienhallinnassa, kuten tarkemmat ennusteet, paremman reagoitokyvyn muutoksiin ja tehokkaamman resurssien käytön. Nämä hyödyt auttavat yrityksiä vähentämään tappioita ja parantamaan kilpailukykyä. Samalla tuodaan esiin haasteita, kuten datan laadun varmistaminen, mallien monimutkaisuus ja jatkuva päivitystarve. Tutkielma korostaa koneoppimisen potentiaalia toimitusketjun hallinnan kehittämisessä ja sen keskeistä roolia tulevaisuuden riskienhallintastrategioissa.

Avainsanat: koneoppiminen, toimitusketjun riskienhallinta, proaktiivisuus, resilienssi

SISÄLLYS

1	Johdanto	7
2	Toimitusketjujen riskienhallinta	10
	2.1 Toimitusketjuriskit	10
	2.2 Toimitusketjun riskienhallintaprosessi	13
	2.3 Riskienhallinnan strategiat	16
3	Koneoppiminen	19
	3.1 Koneoppimisen menetelmät ja sovellukset	19
	3.1.1 Koneoppimisen kolme päätyyppiä	20
	3.1.2 Syväoppiminen	22
4	Koneoppimisen soveltaminen toimitusketjun riskienhallinnassa	24
	4.1.1 Koneoppimisen hyödyt toimitusketjujen riskienhallinnassa	25
	4.1.2 Koneoppimisen haasteet ja rajoitukset toimitusketjun riskienhallinnassa	28
5	Yhteenveto ja johtopäätökset	31
	Lähteet	33

KUVIOT

Kuva 1	Tekoälyn käyttöaste toimitusketju- ja valmistusyrityksissä maailmanlaajuisesti (2022–2025) (Statista 2022)	8
Kuva 2	Toimitusketjun riskiluokat (Christopher & Peck, 2004; Ho ym., 2015)	11
Kuva 3	Riskienhallintaprosessi (Ho ym., 2015)	14
Kuva 4	Keinotekoiset neuroverkot (Usama ym., 2019)	22

1 Johdanto


Nykyaikaiset toimitusketjut ovat pitkiä, globaaleja ja monimutkaisia. Siksi myös toimitusketjuihin liittyvien riskien hallitseminen on jatkuvasti vaikeampaa. Kun riskeihin vaikuttaa useampia tekijöitä, myös niiden vaikutuksista tulee laaja-alaisempia. Toimitusketjun riskien epäonnistunut hallitseminen voi johtaa muun muassa merkittäviin taloudellisiin tappioihin, tuotteiden laadun heikkenemiseen, toimitusten viivästymiseen sekä mainehaittoihin asiakkaiden ja toimittajien silmissä. Näiden vaikutusten minimoimiseksi tehokas toimitusketjun riskienhallinta on kriittisen tärkeää (Cagliano ym., 2012; Heckmann ym., 2015; Ho ym., 2015).

Perinteiset toimitusketjun riskinhallintamenetelmät ovat usein olleet reaktiivisia, ja niiden pääpaino on ollut tapahtuman jälkeisissä analyyseissä sekä historiatiedoissa. Tämä lähestymistapa on rajoittanut niiden kykyä käsitellä reaaliaikaisia häiriöitä, sillä ne keskittyvät pääasiassa häiriöiden ratkaisemiseen vasta niiden ilmettyä (Aljohani, 2023). Yksi ratkaisu tähän ongelmaan on ennakoiva analytiikka ja koneoppiminen. Näiden avulla organisaatiot voivat ennakoivasti tunnistaa ja lieventää riskejä reaaliajassa. Näin toimitusketjut pystyisivät siirtymään reaktiivisesta riskienhallinnasta proaktiiviseen lähestymistapaan, minkä avulla ne voivat välttyä merkittäviltä tappioilta ja ongelmilta (Aljohani, 2023; Baryannis ym., 2018).

Koneoppiminen on erityisen hyödyllinen, kun käsitellään monimutkaisia datajoukkoja, joissa on paljon ulottuvuuksia (eli ominaisuuksia tai muuttujia). Koneoppimisen avulla voidaan oppia historiallisista tiedoista ja löytää datasta toistuvia kaavoja, mikä auttaa tekemään päätöksiä, jotka ovat sekä luotettavia että johdonmukaisesti toistettavia eri tilanteissa (Janiesch ym., 2021). Koneoppimisen nopeaa edistymistä viime vuosina on kiihdyttänyt uusien oppimisalgoritmien ja teorioiden kehittäminen, datan saatavuuden kasvu sekä edullisten laskentamenetelmien lisääntyminen (Jordan & Mitchell, 2015).

Liiketoiminnassa epävarmuudet voivat johtaa vääriin arviointeihin, joilla on merkittäviä seurauksia. Näiden epävarmuuksien jatkuva seuranta ja hallinta on elintärkeää, mikä korostaa ennakoivan analytiikan ja koneoppimisen potentiaalia riskienhallinnan apuna (Heckmann ym., 2015).

Tekoälyn soveltuvuus toimitusketjun monimutkaiseen ja jatkuvasti muuttuvaan ympäristöön näkyy myös Statistan (2022) mukaan tekoälyn käyttöönotoissa toimitusketjuissa ja valmistusteollisuudessa maailmanlaajuisesti. Ennusteen mukaan tekoälyn käyttö yleistyy nopeaa tahtia, ja tekoäly on vuonna 2025 kriittinen osa jopa 38 % toimitusketjuista. Tekoälyn käyttöönotto ei ole enää tulevaisuudessa vain hyödyllistä, vaan myös strateginen edellytys yrityksille, jotka pyrkivät säilyttämään kilpailukykyä ja hallitsemaan riskejä dynaamisessa liiketoimintaympäristössä (Aljohani, 2023; Baryannis ym., 2018).



Kuva 1 Tekoälyn käyttöaste toimitusketju- ja valmistusyrityksissä maailmanlaajuisesti (2022–2025) (Statista 2022)

Tämän tutkielman tarkoituksena on selvittää olemassa olevan kirjallisuuden perusteella koneoppimisen mahdollisuuksia ja soveltamista toimitusketjujen riskienhallinnassa.

Tutkielma pyrkii vastaamaan seuraaviin tutkimuskysymyksiin:

- 1) Miten koneoppimista voidaan hyödyntää toimitusketjun riskienhallinnassa?
- 2) Mitkä ovat koneoppimisen käytön haasteet ja rajoitukset toimitusketjun riskienhallinnassa?

Näiden kysymysten kautta tutkielma tavoittelee selkeää ymmärrystä koneoppimisen potentiaalista ja sen soveltuvuudesta toimitusketjun hallinnassa.

2 Toimitusketjujen riskienhallinta

Riskienhallinta liitetään usein toimitusketjussa kestävyteen (engl. robustness) ja resilienssiin, joilla tarkoitetaan keinoja vähentää toimitusketjun haavoittuvuutta (Baryannis ym., 2018). Kestävyys voidaan määritellä kyvyksi kestää häiriötä hyväksyttävällä suorituskyvyn menetyksellä, kun taas resilienssi tarkoittaa kykyä toipua nopeasti häiriöistä. Toimitusketjun kestävyys korostuu tilanteissa, joissa pyritään hallitsemaan tavanomaisen toiminnan riskejä, eli riskejä, joilla on suuri todennäköisyys ja vähäinen vaikutus. Resilienssi taas korostuu häiriötilanteissa, joissa tapahtuman todennäköisyys on pieni mutta vaikutus suuri (Behzadi ym., 2018). Resilienssin vahvistaminen on yksi olennaisimmista toimitusketjun riskienhallinnan tavoitteista. Toimitusketjun resilienssi perustuu muun muassa joustavuuteen, saatavuuteen, nopeuteen ja näkyvyyteen (Behzadi ym., 2018).

Myös toimitusketjun ketteryys on olennainen termi toimitusketjujen riskienhallintaan liittyen. Toimitusketjun ketteryys (engl. agility) tarkoittaa toimitusketjun kykyä reagoida nopeasti ja tehokkaasti odottamattomiin häiriöihin toimintaa muuttamalla. Ketteryys sisältää sekä taktisen kyvyn reagoida nopeasti muutoksiin että strategisen kyvyn sopeutua muutoksiin. Ketterän toimitusketjun avulla yritys voi saavuttaa kilpailuedun muuttuvassa ja arvaamattomassa liiketoimintaympäristössä. Yksi tärkeimmistä edellytyksistä ketterän toimitusketjun saavuttamiseksi on tehokas riskienhallinta (Aljohani, 2023).

Resilienssi, kestävyys ja ketteryys ovat kaikki tärkeitä ominaisuuksia toimitusketjulle. Tehokkaalla toimitusketjun riskienhallinnalla yritykset pystyvät kehittämään ja ylläpitämään näitä ominaisuuksia, samalla varmistuen kilpailukyvyn säilymisen (Aljohani, 2023; Baryannis ym., 2018; Behzadi ym., 2018).

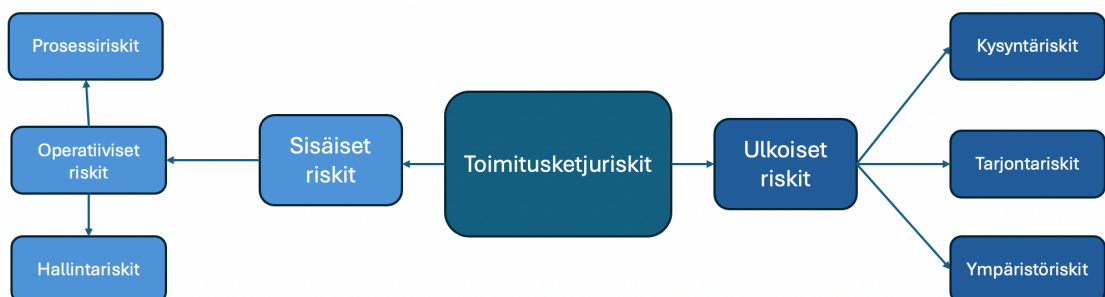
2.1 Toimitusketjuriskit

Toimitusketjuriski on määritelty eri lähteissä jonkin verran vaihtelevasti. Yleisellä tasolla voidaan määritellä, että toimitusketjuriski viittaa erilaisten tapahtumien tai olosuhteiden todennäköisyyteen ja vaikutukseen, jotka voivat kielteisesti häiritä toimitusketjun toimintoja ja johtaa operatiivisen, taktisen tai strategisen tason epäonnistumisiin tai epäsäännöllisyyksiin (Fahimnia ym., 2015; Ho ym., 2015; Kleindorfer & Saad, 2005; Wagner & Bode, 2006). Toimitusketjuriski tarkoittaa siis tapahtumaa, jolla on tietty

todennäköisyys ja mahdolliset negatiiviset vaikutukset (Garvey ym., 2015). Riskiksi voidaan yleistää haavoittuvuus, epävarmuus, häiriö, katastrofi tai vaara. Ennakoinnin puute tällaisista häiriöistä ja niiden vaikutuksista tekee toimitusketjun haavoittuvaiseksi ja altistaa sen toimitusketjuriskeille (Gurtu & Johny, 2021). Nykyaikaisten toimitusketjujen monimutkaisuuden ja verkottuneisuuden vuoksi näitä riskejä on yhä vaikeampi ennustaa ja hallita (Heckmann ym., 2015).

Toimitusketjuriskit voivat johtua monenlaisista lähteistä, ja riskejä luokitellaan useilla eri tavoilla. Riskityyppejä jaotellaan tutkimuksesta riippuen useilla eri tavoilla, mutta ne sisältävät yleensä saman idean eri termeillä. Yksinkertaisimmillaan toimitusketjuriskit voidaan jakaa ulkoisiin ja sisäisiin riskeihin (Christopher & Peck, 2004; Ho ym., 2015). Ulkoiset riskit tarkoittavat yrityksen ympäristöstä aiheutuvia riskejä, joita se ei voi itse hallita. Ulkoisiin riskeihin sisältyvät muun muassa luonnon katastrofit, poliittiset epävakaudet tai muutokset lainsäädännössä. Niiden vaikutukset voivat vaihdella merkittävästi ja organisaatioiden on jatkuvasti seurattava mahdollisten riskien kehittymistä näillä osa-alueilla (Cagliano ym., 2012; van Wyk & Baerwaldt, 2005).

Sisäiset riskit taas liittyvät yrityksen tai toimitusketjun sisällä tehtyihin prosesseihin, toimiin ja päätöksiin. Sisäisiin riskien lähteisiin yritys pystyy vaikuttamaan (Cagliano ym., 2012). Christopher & Peck (2004) jakavat sisäiset riskit prosessi- ja hallintariskeihin. Ulkoiset riskit jaotellaan taas ensin yrityksen ulkoisiin, mutta toimitusketjun sisäisiin riskeihin (kysyntä ja tarjontariskit) sekä täysin ulkoisiin riskeihin (ympäristöriskit).



Kuva 2 Toimitusketjun riskiluokat (Christopher & Peck, 2004; Ho ym., 2015)

Lambert (2008) Jaottelee sisäiset riskilähteet edelleen toimitusketjun kolmen toimintatason mukaan, joilla riskejä voi esiintyä. Nämä tasot ovat strateginen, taktinen ja operatiivinen taso (Lambert, 2008). Manuj & Mentzer (2008) taas määrittelevät riskit kirjallisuuden perusteella neljään luokkaan, jotka ovat tarjonta-, kysyntä-, toiminta- ja turvallisuusriskit.

Operatiiviset riskit, joita kutsutaan myös prosessiriskeiksi (Tang & Tomlin, 2008), liittyvät toimitusketjun päivittäiseen toimintaan ja vaikuttavat organisaation sisäisiin prosesseihin. Ne kuvaavat sisäisiä tapahtumia, jotka häiritsevät yrityksen tuotantoa ja palvelujen tarjoamista, vaikuttaen muun muassa tuotannon laatuun, ajoitukseen ja kannattavuuteen. (Manuj & Mentzer, 2008). Operatiivisiin riskeihin liittyy tapahtumia, jotka voivat häiritä toimitusketjun toimintaa, kuten tuotannon viivästymisiä, laiterikkoja tai laatuongelmia. Ne voivat vaikuttaa merkittävästi organisaation tuloksentelekykyyn ja prosessien tehokkaaseen ylläpitoon (Lockamy & McCormack, 2009).

Tarjontariski (engl. supply risk) liittyy epäsuotuisiin tapahtumiin toimitusketjussa, jotka vaikuttavat yrityksen kykyyn vastata kysyntään sekä määrällisesti että laadullisesti ennakoitujen kustannusten ja aikataulun puitteissa, tai aiheuttaen mahdollisia uhkia asiakkaiden turvallisuudelle (Manuj & Mentzer, 2008). Tang & Tomlin (2008) jakavat tarjontariskit kahteen kategoriaan: Tarjontakustannusriskeihin sekä tarjontasitoumusriskeihin. Tarjontakustannusriskit korostuvat, kun yrityksellä on alhainen neuvotteluvoima ja kontrolli hankintakustannuksista, kun taas tarjontasitoumusriskit liittyvät pitkäaikaisiin sopimuksiin, jotka rajoittavat joustavuutta tilausmäärien muutoksissa.

Kysyntäriski (engl. demand risk) puolestaan liittyy ulkoisiin tekijöihin, jotka heikentävät asiakkaiden tilausten todennäköisyyttä tai aiheuttavat vaihtelua kysytyssä volyymissa (Manuj & Mentzer, 2008). Tang & Tomlin (2008) määrittelevät kysyntäriskin epävarmuutena, joka liittyy tuotteiden tai palvelujen kysynnän määrään ja koostumukseen markkinoilla. Se kuvaa niitä haasteita, joita yritykset kohtaavat yrittäessään ennustaa tuotteidensa tai palveluidensa kysyntää eri markkina-alueilla. Kysyntäriski pitää sisällään sekä myyntivolyymiin että tuotevarianttien kysyntäkoostumukseen liittyvät epävarmuudet, jotka voivat aiheuttaa merkittäviä vaikutuksia muun muassa varastonhallintaan, toimitusketjun suunnitteluun ja yrityksen taloudellisiin tuloksiin.

Ympäristöriski liittyy kaikkiin toimitusketjun ulkopuolisiin riskitekijöihin. Ympäristöriskejä ovat esimerkiksi talousriskit, jotka sisältävät valuuttakurssien vaihtelut, hyödykkeiden hintojen muutokset ja korkojen vaihtelut. Ympäristöriskeihin kuuluvat myös luonnollisten tekijöiden aiheuttamat riskit, kuten tulvat, sekä poliittiset riskit, kuten geopoliittiset epävarmuudet tai kansainvälinen sääntely (Christopher & Peck, 2004; Deiva Ganesh & Kalpana, 2022; Fahimnia ym., 2015).

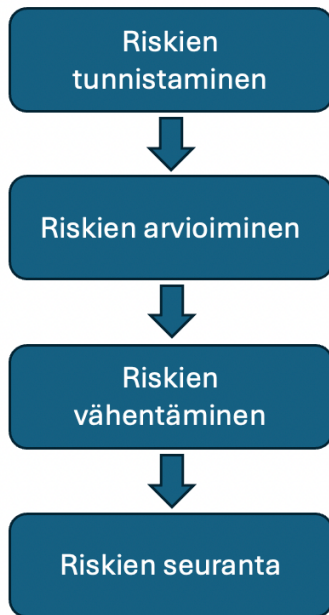
Heckmannin ym. (2015) mukaan toimitusketjuriski taas on puhtaasti tapahtumakeskeinen käsite, ja sitä ei luokitella riskin alkuperäisen syyn tai laukaisevan tekijän mukaan. Heckmannin ym. mukaan toimitusketjun riskienhallinnassa tapahtumia luonnehditaan niiden esiintymistodennäköisyydellä ja niihin liittyvillä seurauksilla toimitusketjussa.

Tässä luvussa tarkasteltujen riskien monimuotoisuuden perusteella voimme todeta, ettei toimitusketjun riskeille ole yksiselitteistä luokittelua, vaan kirjallisuudesta löytyy useita versioita, joiden perusteella riskit jaotellaan niiden ominaisuuksien mukaan.

2.2 Toimitusketjun riskienhallintaprosessi

Toimitusketjun riskienhallinnalla tarkoitetaan jäseneltyä lähestymistapaa toimitusketjun riskien hallitsemiseen, joka sisältää strategioiden kehittämisen näiden riskien lieventämiseksi ennen niiden esiintymistä, sekä vastaamisen riskeihin, jos ne tapahtuvat. Riskienhallinta pyrkii varmistamaan toimitusketjun sujuvuuden toteuttamalla strategioita ja käytäntöjä, jotka perustuvat jatkuvaan riskien arviointiin, tunnistamiseen ja minimointiin. Näin pyritään ehkäisemään mahdolliset heikkoudet toimitusverkostoissa, mikä vahvistaa toimitusketjun resilienssiä (Gurtu & Johny, 2021; Ho ym., 2015).

Viimeisen vuosikymmenen aikana toimitusketjun riskienhallinnan alalla on tapahtunut merkittävää kehitystä, kun sekä laadullisia että määrällisiä menetelmiä ja välineitä on kehitetty ja otettu käyttöön. Toimitusketjun riskienhallinta prosessi voidaan tyypillisesti jakaa neljään päävaiheeseen, jotka ovat riskien tunnistaminen (engl. identification), riskien arviointi (engl. assesment), riskien vähentäminen (engl. mitigation) ja riskien seuranta (engl. monitoring) (Behzadi ym., 2018; Ho ym., 2015; Juttner, 2005; Manuj & Mentzer, 2008). Kuhunkin näistä vaiheista on kehitetty ja sovellettu erilaisia menetelmiä ja välineitä (Ho ym., 2015).



Kuva 3 Riskienhallintaprosessi (Ho ym., 2015)

Ensimmäinen vaihe riskienhallinta prosessissa on riskien tunnistaminen. Riskien tunnistaminen on järjestelmällinen prosessi, joka pyrkii tunnistamaan toimitusketjun riskit ja niiden seuraukset mahdollisimman kattavasti. On tärkeää, että tunnistus vaiheessa vaikutuksen alaiset alueet määritetään selkeästi ja seurauksien laajuudesta saadaan tarkka kuva. Nämä ovat edellytyksiä, jotta riskien lieventäminen ja ehkäisy voidaan suorittaa tehokkaasti ja tarkasti myöhemmissä vaiheissa. Tunnistaminen sisältää sekä sisäisten että ulkoisten riskien kartoituksen, ja se perustuu historialliseen dataan, oletuksiin tulevasta sekä asiantuntija-arvioihin. Toimitusketjun ympäristö muuttuu jatkuvasti, ja tunnistaminen edellyttää jatkuvaa kehitystä ja adaptaatiota uusiin tietoihin ja markkinoiden muutoksiin. Riskien tunnistamisessa hyödynnetään usein perinteisiä menetelmiä, kuten toimitusketjun kartoitusta tai vika- ja vaikutusanalyysiä (engl. Failure mode and effects analysis) (Cagliano ym., 2012; Ho ym., 2015; Tummala & Schoenherr, 2011).

Caglianon ym., (2012) mukaan riskien tunnistamiseen toimitusketjussa on kaksi pääasiallista lähestymistapaa. Ensimmäinen perustuu aivoriiheen ja pyrkii määrittämään mahdollisia riskejä sekä niiden syy-seuraussuhteita haastattelemalla ja kuulemalla alan asiantuntijoita. Toinen lähestymistapa keskittyy taksonomioiden kehittämiseen, jotka

luokittelevat toimitusketjun riskit ja niiden lähteet esimerkiksi materiaalin, informaation ja taloudellisten virtausten mukaan.

Riskien tunnistamisvaiheen lopuksi yhdistetään havaitut riskien lähteet toimitusketjun prosesseja vastaaviin toimintoihin. Kun riskien lähteet on tunnistettu, on tärkeää arvioida riskien esiintymisen luonnetta ja vaikutuksia. Minkälaisia riskitapahtumia lähde voi aiheuttaa riskiin yhdistetylle toiminnolle, ja mitkä ovat niiden vaikutukset, kuten aikatauluviiveet tai laatuongelmat. Nämä tiedot ohjaavat toimintaa riskienhallinta prosessin seuraavassa vaiheessa, eli riskien arviointi vaiheessa (Cagliano ym., 2012).

Toinen vaihe riskienhallinta prosessissa on riskien arviointi ja analysoiminen. Kuten mainittu, riskien arviointivaiheen kannalta on tärkeää, että ensimmäinen vaihe on suoritettu huolellisesti ja siinä on saatu selkeä kuva riskien lähteistä, niihin liittyvistä prosesseista sekä mahdollisista vaikutuksista. Toimitusketjun riskityyppien tarkka ymmärtäminen riskien tunnistus ja arviointi vaiheissa mahdollistaa tehokkaan riskien lieventämisen (Cagliano ym., 2012).

Tunnistusvaiheessa suoritettu riskien luokittelu on tärkeää, jotta voidaan saavuttaa toimitusketjulle asetetut tavoitteet. Riskien arvioinnin tavoitteena on määrittää, mitkä riskit vaativat eniten huomiota ja resursseja, jotta niiden vaikutus yrityksen toimintaan voidaan ymmärtää paremmin. Riskien priorisoiminen arvioinnin perusteella on kriittistä toimitusketjun tehokkuuden ja resurssien käytön kannalta (Heckmann ym., 2015; Tummala & Schoenherr, 2011).

Riskien arviointi suoritetaan niiden vaikutusten ja todennäköisyyden mukaan. Riskejä analysoitaessa valitaan prosesseja tukevat suorituskykymittarit, jotka auttavat kuvaamaan riskien vaikutuksia ja arvioimaan tunnistettujen riskilähteiden aiheuttamien riskitapahtumien todennäköisyyksiä ja seurauksia. Oikein valitut suorituskykymittarit yhdistettynä tarkkaan seurantaprosessiin mahdollistavat poikkeamien valvonnan ennalta laadituista suunnitelmista ja varmistavat, että huomio kiinnitetään nopeasti mutta selkeästi niihin toimitusketjun osa-alueisiin, jotka vaativat eniten huomiota. Tämä mahdollistaa perusteellisemman tutkimuksen ja tiedonhankinnan niille riskeille, jotka ovat kriittisimpiä organisaation toiminnalle ja joita on priorisoitu tehokkaan riskienhallinnan strategiassa (Cagliano ym., 2012; Heckmann ym., 2015).

Riskien lieventäminen on riskienhallintaprosessin kolmas vaihe, jossa strategioita ja toimenpiteitä kehitetään tunnistettujen ja arvioitujen riskien hallitsemiseksi ja minimoimiseksi. Tehokas riskien lieventäminen edellyttää tarkkaa ymmärrystä eri riskien vaikutuksista ja seurauksista. Riskien lieventämiseen liittyy useita eri strategioita, joiden valinta perustuu riskien luonteeseen, ja ne on sovitettava yrityksen toimitusketjun erityispiirteisiin. Riskien lieventämisen strategioita ovat esimerkiksi ennaltaehkäisy ja uudelleen aikatauluttaminen (Behzadi ym., 2018; Gurtu & Johny, 2021; Ho ym., 2015).

Riskien lieventämisvaiheessa korostetaan toimitusketjun kriittisten osa-alueiden tunnistamista ja suojaamista sekä valmiuksia nopeaan toimintaan ja sopeutumiseen yllättävissä tilanteissa. Tämä vaihe yhdistää ennakoivat ja reaktiiviset strategiat, joiden avulla yritykset voivat hallita riskejä proaktiivisesti ja varautua mahdollisiin häiriöihin. Riskien lieventäminen vaatii jatkuvaa seuranta, ennakoivaa suunnittelua ja joustavuutta. Tehokas riskien lieventäminen johtaa kestävään, resilienttiin ja ketterään toimitusketjuun (Christopher & Peck, 2004; Heckmann ym., 2015; Ho ym., 2015; Sreedevi & Saranga, 2017).

Riskienhallintaprosessin viimeinen vaihe, Riskien seuranta on jatkuva prosessi, jossa yritykset tarkkailevat ja arvioivat toimitusketjun riskienhallintastrategioiden tehokkuutta. Tämä sisältää toimitusketjun suorituskyvyn jatkuvaa mittaamista ja riskienhallintasuunnitelmien päivittämistä. Seuranta varmistaa, että yritys voi reagoida nopeasti, jos riskit alkavat kehittyä odottamattomalla tavalla, ja että yritys voi oppia ja mukautua jatkuvasti muuttuvaan riskiympäristöön. Riskien seuranta eroaa aiemmista riskien hallintaprosessin vaiheista siinä, että seuranta tapahtuu vasta, kun riskistrategia on jo paikallaan ja toiminnassa. Kun yritys on luonut toimintasuunnitelman riskien käsittelyyn, tiimi voi seurata sen vaikutusta ja tehokkuutta. Tehokas riskien seuranta edesauttaa ennakoivaa riskienhallintaa ja kehittää yrityksen resilienssiä (Cagliano ym., 2012; Ho ym., 2015; Moon & Krahel, 2020).

2.3 Riskienhallinnan strategiat

Toimitusketjun riskienhallintaan liittyy useita erilaisia strategioita, joita yritysten on jatkuvasti päivitettävä ja seurattava. Manuj & Mentzer (2008) esittävät tutkimuksessaan, että toimitusketjun riskienhallinnan strategioihin vaikuttavat olennaisesti ajallinen painopiste, toimitusketjun joustavuus ja ympäristö. Strategian valinta sekä sen

onnistuminen riippuvat toimitusketjun monimutkaisuudesta ja organisaatioiden välisestä oppimisesta.

Baryannis ym., (2018) mukaan toimitusketjun riskienhallinnassa voidaan noudattaa joko reaktiivista tai proaktiivista strategiaa. Yritysten tulisi pyrkiä käyttämään nimenomaan proaktiivisia strategioita, sillä ne mahdollistavat riskien ennakoinnin ja niiden mahdollisten vaikutusten minimoinnin jo ennen niiden toteutumista. Tämä lähestymistapa on osoittautunut tehokkaaksi tappioiden estämisessä verrattuna reaktiivisiin strategioihin, jotka keskittyvät ongelmien ratkaisemiseen niiden ilmettyä.

Tang & Tomlin (2008) jakavat toimitusketjun riskienhallinnan strategiat kahteen ryhmään: lieventämisstrategioihin ja varautumisstrategioihin. Lieventämisstrategioita toteutetaan ennakoivasti ennen riskin tapahtumista, ja varautumisstrategioiden avulla suunnitellaan riskeihin reagoiminen riskitapahtumien tapahtuessa. Molemmat strategiat ovat välttämättömiä toimitusketjun häiriöiden minimoimisessa ja liiketoiminnan jatkuvuuden varmistamisessa (Behzadi ym., 2018).

Gurtu & Johny (2012) taas laajentavat näkemystä jakamalla riskienhallinnan strategiat seitsemään kategoriaan, jotka keskittyvät erilaisiin toimenpiteisiin riskien hallitsemiseksi. Näihin kuuluvat ennaltaehkäisy, aikataulujen muuttaminen, arvelu, numeerinen ja taloudellinen, vertikaalinen integraatio, riskien jakaminen sekä teknologia ja turvallisuus. Nämä kategoriat tarjoavat työkalut monenlaisiin uhkiin.

Vaikka proaktiiviset strategiat ovat osoittautuneet selkeästi tehokkaimmiksi, myös reaktiivisia strategioita sovelletaan usein käytännössä. Proaktiivisten strategioiden käyttöönotto ja ylläpitäminen vaatii paljon investointeja, resursseja sekä tietoa, minkä vuoksi useilla yrityksillä ei ole tarvittuja ominaisuuksia näiden strategioiden käyttämiseen. Lisäksi investointeja ennaltaehkäiseviin toimenpiteisiin ei välttämättä nähdä tarpeellisina, erityisesti kun riskit eivät ole vielä toteutuneet ja niiden kustannukset voivat olla vaikeita perustella (Behzadi ym., 2018).

Tämän luvun perusteella voimme todeta, että toimitusketjun riskienhallinta on monimutkainen prosessi, joka vaatii jatkuvaa tarkkailua, päivittämistä, oppimista sekä kykyä sopeutua nopeasti muuttuviin olosuhteisiin. Riskienhallinnan strategioiden tehokas toteuttaminen vaatii kattavaa sitoutumista kaikilta yrityksen tasoilta ja kumppaneilta, jotta

voidaan varmistaa toimitusketjun kestävyys, resilienssi ja kilpailukyky pitkällä tähtäimellä.

3 Koneoppiminen

Tekoälyllä viitataan joukkoon analyttisiä algoritmeja, joiden avulla tietokoneet pystyvät suorittamaan tehtäviä, jotka perinteisesti ovat vaatineet inhimillistä älykkyyttä. Nämä tehtävät sisältävät monenlaisia toimintoja, kuten oppiminen, päätöksenteko, ongelmanratkaisu ja kuvioiden- sekä mallientunnistus. Tekoälyjärjestelmät on suunniteltu toimimaan mahdollisimman vähällä ihmisen osallistumisella. Ne tunnistavat oivalluksia datasta ilman tarkkaa ohjelmointia siitä, mistä etsiä. Tekoäly perustuu analyttisiin malleihin, jotka tuottavat ennusteita, sääntöjä, vastauksia, suosituksia tai vastaavia tuloksia (Janiesch ym., 2021; Kaplan, 2016; Shameer ym., 2018).

Koneoppiminen on yksi tekoälyn osa-alueista. Se perustuu järjestelmien kykyyn oppia datasta. Koneoppiminen pyrkii parantamaan järjestelmien suorituskkyä ajan mittaan tietyissä tehtävissä ilman, että niitä ohjelmoidaan siihen suoraan. Koneoppiminen sisältää algoritmeja, jotka oppivat automaattisesti tunnistamaan malleja ja kuvioita, tekemään päätöksiä sekä ennustamaan tuloksia syötetyn datan perusteella. Se eroaa perinteisistä ohjelmointimenetelmistä, joissa päätöksenteko perustuu manuaalisesti luotaviin tarkkoihin sääntöihin (Janiesch ym., 2021; Libbrecht & Noble, 2015).

Koneoppimisen tavoitteena on automatisoida analyttinen mallintaminen, mikä mahdollistaa kognitiivisten tehtävien suorittamisen, kuten kohteiden tunnistamisen tai luonnollisen kielen käsittelyn. Algoritmit koulutetaan harjoitusdatalla, jonka avulla ne iteratiivisesti kehittävät ymmärrystään aineistosta, jolloin ne voivat tuottaa päätelmiä ja löytää oivalluksia ilman ihmisen suoraa ohjeistusta. Tämä prosessi mahdollistaa sen, että koneoppimisjärjestelmät pystyvät mukautumaan ja oppimaan reaali maailman ilmiöistä, mikä tekee niistä erittäin tehokkaita ja monipuolisia sovelluksissa, jotka edellyttävät monimutkaisten ongelmien ratkaisemista (Baryannis ym., 2019; Janiesch ym., 2021; Schroeder & Lodemann, 2021; Tirkolae ym., 2021).

3.1 Koneoppimisen menetelmät ja sovellukset

Koneoppiminen sisältää useita eri algoritmeja, jotka vaihtelevat monimutkaisuudeltaan ja soveltuvuudeltaan. Tarkat algoritmit tietyille koneoppimismalleille valitaan oppimistehtävän mukaan, eli algoritmit mukautetaan ratkaistavan ongelman tavoitteisiin sopiviksi. Yleisimpiä algoritmiluokkia koneoppimisessa ovat esimerkiksi regressiomallit, päätöspuut, bayesilaiset menetelmät ja neuroverkot. Menemättä tarkempiin

yksityiskohtiin, regressiomallit sopivat jatkuvien arvojen ennustamiseen, päätöspuut soveltuvat hyvin luokittelutehtäviin, bayesilaiset menetelmät perustuvat todennäköisyyslaskentaan ja ne sopivat esimerkiksi luokittelutehtäviin, jotka sisältävät epävarmuutta. Neuroverkot taas ovat monimutkaisia malleja, jotka matkivat ihmisaivojen toimintaa ja ovat tehokkaita monenlaisissa ennustustehtävissä (Baryannis ym., 2019; Janiesch ym., 2021; Jordan & Mitchell, 2015).

Koneoppimisen sovelluksilla on yleensä kaksi tavoitetta: mahdollisimman tarkka ennustaminen tai tulosten selkeä tulkinta. Näiden kahden päämäärän saavuttamisen välillä on kuitenkin kompromisseja. Jos tuloksista halutaan helposti tulkittavia, yleensä ennustetarkkuus kärsii (Baryannis ym., 2019; Libbrecht & Noble, 2015).

3.1.1 Koneoppimisen kolme päätyyppiä

Koneoppimisesta voidaan erottaa kolme oppimisen päätyyppiä: valvottu oppiminen, valvomaton oppiminen ja vahvistusoppiminen (Janiesch ym., 2021; Libbrecht & Noble, 2015; Murphy, 2012).

Valvottu oppiminen (engl. supervised learning) tarkoittaa koneoppimismallin kouluttamisen merkityllä datalla, jossa syöte on yhdistetty oikeaan tulokseen. Koulutusvaiheessa malli oppii yhdistämään syöteen sekä sitä vastaavan tuloksen. Koulutusvaiheen jälkeen tätä opittua mallia voidaan käyttää ennusteiden tekemiseen uudella, tuntemattomalla datalla. Tarkkuus ja kyky tehdä oikeita ennusteita ovat mallin suorituskyvyn keskeisiä mittareita, ja valvottu oppiminen on hyödyllistä erityisesti tehtävissä, joissa tarvitaan selkeitä ennusteita ja päätöksiä (Janiesch ym., 2021; Jordan & Mitchell, 2015; Libbrecht & Noble, 2015; Wichmann ym., 2020).

Valvottua oppimista käytetään esimerkiksi kuvantunnistuksessa, jossa malli voi oppia tunnistamaan ja luokittelemaan kuvat perustuen koulutusdataan, jossa jokainen kuva on merkitty sen sisältämän kohteen mukaan. Näin malli oppii tunnistamaan kuvioita ja piirteitä, jotka määrittelevät kunkin luokan (Libbrecht & Noble, 2015).

Valvomaton oppiminen (engl. unsupervised learning) taas tarkoittaa prosessia, jossa koneoppimismalli koulutetaan merkkeamattomalla datalla, eli se oppii analysoimaan ja jäsentämään dataa ilman ennalta annettuja vastauksia tai merkintöjä. Toisin kuin valvotussa oppimisessa, malli ei saa tietoa siitä, mitkä syötteet johtavat mihinkin

tulokseen, vaan sen tulee itse löytää piilotetut rakenteet ja yhteydet datan sisällä (Janiesch ym., 2021; Usama ym., 2019).

Valvomattomassa oppimisessa koulutusdata koostuu pelkistä muuttujista, joista koneoppimismallin tavoitteena on löytää rakenteellista tietoa. Valvomattomassa oppimisessa on yleisesti ottaen kaksi päämenetelmää: klusterointi ja dimensionaalisuuden vähentäminen. Klusteroinnissa koneoppimismalli pyrkii jakamaan datan ryhmiin (klustereihin), jotka perustuvat datan ominaisuuksiin. Dimensionaalisuuden vähentämisessä malli taas keskittyy datan ulottuvuuksien määrän vähentämiseen eli se pyrkii vähentämään datan monimutkaisuutta (Janiesch ym., 2021; Jordan & Mitchell, 2015; LeCun ym., 2015).

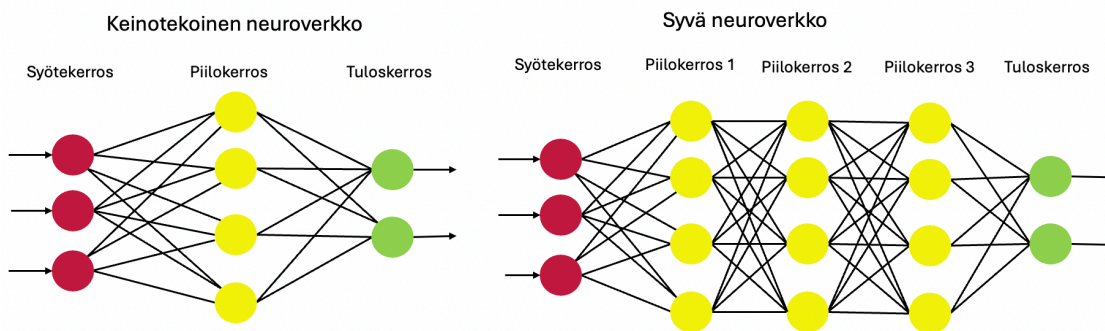
Valvomattoman oppimisen menetelmiä käytetään toistaiseksi selvästi vähemmän kuin valvotun oppimisen menetelmiä, sillä valvomatonta oppimista on huomattavasti vaikeampaa hyödyntää. Teknologian ja menetelmien kehittyessä valvomattoman oppimisen kuitenkin odotetaan ottavan tärkeämpi asema sen laajojen sovellusmahdollisuuksien takia (LeCun ym., 2015; Usama ym., 2019).

Vahvistusoppiminen (engl. reinforcement learning) on koneoppimisen menetelmä, jossa oppimisprosessi ohjataan palkkiosignaalien avulla. Nämä signaalit seuraavat agentin tehtyjä toimia ja niiden tuloksia ympäristössä. Menetelmä hyödyntää kokemusta ja evaluatiivista palautetta, parantaen näin järjestelmän kykyä tehdä käyttäytymispäätöksiä. Vahvistusoppiminen pyrkii parantamaan päätöksentekoa havaitsemalla, miten eri toiminnot vaikuttavat ympäristöön ja millaisia palkkioita ne tuottavat. Koneoppimismallin tavoite on tällöin oppia tekemään toimintoja, jotka maksimoivat kumulatiivisen palkkion pitkällä aikavälillä (Janiesch ym., 2021; Jordan & Mitchell, 2015; Littman, 2015).

Vahvistusoppimisessa agentti tekee päätöksiä vuorovaikutuksessa ympäristön kanssa ja saa palautetta päätösten seurauksista. Koulutusdata vahvistusoppimisessa antaa viitteitä siitä, onko toiminta oikein vai väärin, mutta ei suoraan kerro, miten toimia. Tämä tarkoittaa, että agentin on itse kokeiltava eri toimintoja ja arvioitava niiden seurauksia. Vahvistusoppiminen soveltuu erityisesti suljettuihin ympäristöihin. Esimerkkinä tällaisesta ovat monimutkaiset lautapelit, kuten shakki, joissa koneoppimismallit ovat vahvistusoppimisen avulla oppineet hallitsemaan peliä (Janiesch ym., 2021; Jordan & Mitchell, 2015; Littman, 2015).

3.1.2 Syväoppiminen

Syväoppiminen (engl. deep learning) on koneoppimisen edistynyt osa-alue, joka hyödyntää monikerroksisia (syviä) neuroverkkoja datan esitystapojen automaattiseen oppimiseen. Keinotekoiset neuroverkot (engl. artificial neural networks) ovat koneoppimisen algoritmeja, jotka jäljittelevät ihmisaivojen neuronien toimintaa ja välittävät signaaleja kerrosten välillä. Neuroverkot järjestetään kerroksiin, joissa syötekerros vastaanottaa datasyötteen, piilokerrokset käsittelevät tietoa oppimalla syötteen ja tuloksen välistä suhdetta, ja tuloskerros tuottaa lopullisen tuloksen. Vaikka suuri osa syväoppimisen käytännön menestyksestä on tullut valvotun oppimisen menetelmistä, on myös pyritty kehittämään syväoppimisalgoritmeja, jotka löytävät hyödyllisiä representaatioita syötteestä valvomattoman oppimisen mukaisesti (Janiesch ym., 2021; Jordan & Mitchell, 2015; LeCun ym., 2015; Wichmann ym., 2020).



Kuva 4 Keinotekoiset neuroverkot (Usama ym., 2019)

Syväoppimisen vahvuus on kyvyssä oppia monitasoisia dataesityksiä, jotka sisältävät tarkkoja yksityiskohtia tai monimutkaisia kokonaisuuksia. Tämä mahdollistaa syväoppimisen soveltamisen erityisesti suurten ja monimutkaisten datamäärien käsittelyyn, joissa se voi tunnistaa piileviä kuvioita ja rakenteita, jotka ovat liian monimutkaisia perinteisille koneoppimismenetelmille. Syväoppiminen on erityisen tärkeä koneoppimisen menetelmä, koska sen monikerroksiset neuroverkot pystyvät oppimaan ja sopeutumaan ilman ennalta määriteltyjä ohjeita, mikä tekee siitä erinomaisen työkalun haasteellisten ongelmien ratkaisemiseen. Syväoppimismallit hyödyntävät takaisinkytkentäalgoritmeja virheiden pienentämiseksi ja tarkemman datan esitystavan

kehittämiseksi, mikä johtaa tarkempiin ennusteisiin ja päätöksiin (Janiesch ym., 2021; LeCun ym., 2015; Wichmann ym., 2020).

Syväoppimisen kyky käsitellä ja analysoida suuria ja monimuotoisia datajoukkoja tekee siitä arvokkaan työkalun eri sovelluskohteille. Viimeaikaiset kehitykset syväoppimisen valvomattomissa tekniikoissa ajavat koneoppimisen potentiaalia ja hyötyjä nopeasti eteenpäin, kun raakadataa pystytään käsitellä tehokkaammin ja ilman laajaa ja spesifiä tietämystä alasta (Usama ym., 2019).

4 Koneoppimisen soveltaminen toimitusketjun riskienhallinnassa

Toimitusketjun riskienhallinta käsittää monenlaisia strategioita, joilla pyritään tunnistamaan, arvioimaan, lieventämään ja seuraamaan odottamattomia tapahtumia ja niiden vaikutuksia. Toimitusketjun riskienhallintastrategiat ovat usein riippuvaisia nopeasta ja mukautuvasta päätöksenteosta, joka perustuu laajoihin ja moniulotteisiin tietolähteisiin. Nämä ominaisuudet toimitusketjun riskienhallinnassa tekevät siitä sopivan sovelluskohteen myös koneoppimisen menetelmille (Baryannis ym., 2018).

Koneoppimisen soveltaminen toimitusketjun riskienhallinnassa on noussut tärkeäksi menetelmäksi, jolla voidaan parantaa toimitusketjujen tehokkuutta ja kustannustehokkuutta sekä ennustaa, arvioida ja lieventää riskejä ennakoivasti ja tehokkaasti. Koneoppiminen mahdollistaa monimutkaisten ja laajojen datalähteiden nopean käsittelyn ja analysoinnin, mikä on tärkeää toimitusketjujen monimutkaisessa ja jatkuvasti muuttuvassa toimintaympäristössä (Schroeder & Lodemann, 2021; Tirkolae ym., 2021). Koneoppimismenetelmät auttavat tunnistamaan kuvioita ja trendejä, joita on perinteisillä menetelmillä hankalaa havaita, mahdollistaen näin riskien aikaisen tunnistamisen ja ennaltaehkäisyn (Baryannis ym., 2018; Schroeder & Lodemann, 2021; Tirkolae ym., 2021).

Erityisesti koneoppiminen soveltuu toimitusketjun riskienhallintaan tarkkojen ennusteiden tekemisessä ja mallinnuksessa. Tekniikka käyttää hyväkseen sekä historiallista että reaaliaikaista dataa, jonka pohjalta se ennustaa potentiaalisia häiriöitä ja optimoi päätöksentekoprosesseja. Näin yritykset voivat siirtyä reaktiivisesta riskienhallinnasta kohti proaktiivista lähestymistapaa (Baryannis ym., 2019; Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021; Tirkolae ym., 2021).

Koneoppiminen tukee myös tietoon perustuvaa päätöksentekoa tarjoamalla luotettavia ennusteita ja analyyskejä, jotka auttavat ymmärtämään paremmin toimitusketjun ympäristöä ja tunnistamaan potentiaaliset riskit (Deiva Ganesh & Kalpana, 2022; Tirkolae ym., 2021). Lisäksi koneoppimisen avulla voidaan automatisoida toistuvia ja aikaa vieviä analyysitehtäviä, mikä mahdollistaa henkilöstön keskittymisen strategisempiin linjoihin (Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021; Tirkolae ym., 2021).

Koneoppimismallit tarjoavat parannettua tarkkuutta riskiarvioihin käsittelemällä suuria tietomääriä tehokkaammin ja tarkemmin kuin perinteiset menetelmät, mikä johtaa nopeampiin ja luotettavampiin vastauksiin (Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021). Tämä tarkkuus yhdistettynä koneoppimisen kykyyn mukautua ja skaalautua toimitusketjun tarpeiden mukaan tekee siitä erinomaisen työkalun globaalien toimitusketjujen hallintaan (Tirkolae ym., 2021).

Ennalta mainittujen ominaisuuksien ansiosta koneoppimisen soveltuu toimitusketjun riskienhallintaan erinomaisesti. Seuraavaksi tarkastellaan koneoppimisen hyötyjä ja rajoituksia alan tutkimusten mukaan.

4.1.1 Koneoppimisen hyödyt toimitusketjujen riskienhallinnassa

Koneoppimisella on paljon potentiaalisia hyötyjä, kun se saadaan integroitua toimitusketjun riskienhallintaan. Koneoppimisen avulla yritykset pystyvät merkittävästi parantamaan toimitusketjun riskienhallinnan kautta tehokkuutta, kustannustehokkuutta, ja kykyä reagoida nopeasti ympäristön muutoksiin. Alla käsittelen tarkemmin koneoppimisen olennaisimpia hyötyjä alan tutkimusten sekä tapausesimerkkien kautta.

Ensimmäisenä koneoppimisen hyötynä toimitusketjun riskienhallinnassa käsitellään riskien varhainen havaitseminen ja ennakointi. Koneoppimisen avulla voidaan tunnistaa ja ennustaa riskejä ajoissa, mikä mahdollistaa ennaltaehkäisevät toimenpiteet ennen riskien realisoitumista. Kyky tunnistaa riskejä ja lieventää niiden vaikutuksia ennen kuin ne ilmenevät tekee toimitusketjusta kestävä ja resilientin. (Baryannis ym., 2018, 2019). Koneoppimisen kyky mallintaa ja ennustaa tulevia trendejä auttaa yrityksiä valmistautumaan ja sopeutumaan jatkuvasti muuttuviin olosuhteisiin. Tämä ennakoiva toiminta on keskeistä, kun tavoitteena on minimoida riskien vaikutukset ja optimoida toimitusketjun tehokkuus (Deiva Ganesh & Kalpana, 2022).

Toisena hyötynä koneoppiminen mahdollistaa nopean reagoinnin ympäristön muutoksiin ja häiriöihin. Tämä lisää toimitusketjun joustavuutta ja mahdollistaa nopeat muutokset operatiivisissa toimenpiteissä, mikä on kriittistä toimitusketjun nopeasti muuttuvassa ja häiriöille alttiissa markkinaympäristössä. Koneoppimisen kyky ennustaa ja havaita häiriöitä etukäteen parantaa yritysten kykyä reagoida nopeasti muutoksiin ja häiriöihin. Tämä on avainasemassa, kun pyritään ylläpitämään tehokasta riskien hallintaa (Toorajipour, Baryannis, Tirkolae, Deiva, Lodemann, Aljohani).

Kolmas koneoppimisen hyöty liittuen toimitusketjun riskienhallintaan on parempi päätöksenteko. Koneoppimisen avulla voidaan tuottaa tarkkoja analyyskejä ja ennusteita, jotka pohjautuvat laajoista tietokannoista kerättyyn tietoon. Tämä tietoon perustuva päätöksenteko auttaa yrityksiä tekemään perusteltuja ja tehokkaita päätöksiä riskienhallinnassa. Koneoppimisen avulla päätöksenteko muuttuu johdonmukaisemmaksi ja vähemmän alttiiksi inhimillisille virheille. Tietoon perustuva päätöksenteko korostuu toimitusketjujen riskienhallinnassa, sillä päätöksiin vaikuttava useita monimutkaisia tekijöitä (Baryannis ym., 2019; Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021; Tirkolae ym., 2021; Toorajipour ym., 2021).

Neljäntenä hyötynä koneoppimisen avulla toimitusketjun riskienhallinnassa voidaan saavuttaa kustannustehokkaampi toimitusketju. Automaation ja tarkempien ennusteiden myötä koneoppiminen auttaa vähentämään virheitä, hukkaa ja kustannuksia. Koneoppiminen automatisoi toistuvia ja aikaa vieviä analyysitehtäviä, mikä vapauttaa resursseja strategisempiin tehtäviin ja parantaa toiminnallista tehokkuutta. Tämä nostaa koko toimitusketjun suorituskykyä ja vähentää inhimillisten virheiden määrää, mikä johtaa taloudellisiin säästöihin ja parempaan resurssien allokaatioon koko toimitusketjussa (Baryannis ym., 2019; Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021; Tirkolae ym., 2021; Toorajipour ym., 2021).

Viimeisenä hyötynä käsitellään koneoppimismallien skaalautuvuus. Koneoppimismalleja voidaan räätälöidä ja skaalata vastaamaan erilaisia toimitusketjun tarpeita ja haasteita. Lisäksi koneoppimismalleja pystytään (ja pitääkin) päivittää jatkuvasti. Tämä lisää niiden potentiaalia toimitusketjujen riskienhallinnassa, alasta tai maantieteellisestä sijainnista riippumatta (Baryannis ym., 2019; Tirkolae ym., 2021).

Aljohani (2023) sekä Schroeder & Lodemann (2021) tutkivat molemmat koneoppimisen hyötyjä erilaisten tapausesimerkkien kautta. Käsitelen seuraavaksi koneoppimisen hyötyjä näiden konkreettisten esimerkkien kautta, joissa yritykset ovat saavuttaneet merkittäviä hyötyjä toimitusketjujen riskienhallinnassa koneoppimisen avulla.

Autoteollisuudessa koneoppiminen mahdollisti tunnetun autonvalmistajan parantavan just-in-time-tuotantoprosessejaan ja minimoivan komponenttitoimitusten katkokset. Autovalmistaja pystyi näin ylläpitämään operatiivista tehokkuuttaan paremmin sekä vähentämään taloudellisia tappioitaan huomattavasti. Ennustavien koneoppimismallien avulla yritys kykeni ajoissa havaitsemaan potentiaaliset häiriöt, minkä ansiosta se pystyi

muokkaamaan tuotantoon häiriön vaatimalla tavalla. Tämän seurauksena toimitusvarmuus kasvoi ja tuotannon tehokkuus parani merkittävästi (Aljohani, 2023).

Toisessa esimerkissä suuri vähittäismyyntiketju otti käyttöön koneoppimisen parantaakseen kysynnän ennustamisen tarkkuutta ja varastonhallintaa. Koneoppimismalleilla analysoitiin aiempia myyntitietoja ja kuluttajien ostokäyttäytymistä sekä ulkoisia tietolähteitä, kuten markkinoiden tilaa ja taloudellisia indikaattoreita. Tämän seurauksena yritys pystyi optimoimaan hinnoittelua ja kampanjoita sekä hallitsemaan varastoaan tehokkaammin, mikä johti korkeampaan asiakastyytyvyyteen ja kasvaneeseen myyntituloon (Aljohani, 2023).

Kolmannessa esimerkissä merkittävä lääkeyhtiö käytti koneoppimista varmistaakseen toimittajiensa noudattavan säädöksiä ja ylläpitääkseen tuotteidensa laatua. Ennustavien mallien avulla yritys tunnisti toimittajat, jotka mahdollisesti rikkoivat säädöksiä tai joilla oli eheyteen liittyviä ongelmia. Aikainen havaitseminen mahdollisti nopeat toimenpiteet, kuten tarkennetut auditoinnit ja toimittajien kanssa tehtävän yhteistyön tehostamisen. Tämä vähensi sääntelyyn liittyviä sakkoja, paransi tuotteiden laatua, sekä lisäsi toimittajaverkoston luotettavuutta (Aljohani, 2023).

Teknologia-alalla taas koneoppiminen auttoi yritystä ehkäisemään globaalien toimitusketjujen geopoliittisia riskejä. Mallit ennustivat poliittisten tapahtumien ja kauppapolitiikan muutosten vaikutuksia toimitusketjuun, mahdollistaen ennakoivat toimet, jotka suojasivat yritystä ja sen asiakkaita geopoliittisilta häiriöiltä. Käytännössä tämä vähensi toimitushäiriöitä ja taloudellisia tappioita, sekä paransi operatiivista toiminnan ylläpitoa (Aljohani, 2023).

Volkswagen on hyödyntänyt koneoppimista toimittajien valinnassa. Yritys on kehittänyt koneoppimiseen perustuvan järjestelmän, joka tunnistaa mahdollisia toimittajia tarkasti ja nopeasti. Tämän järjestelmän avulla Volkswagen pyrkii minimoimaan hankintaan liittyviä viiveitä ja riskejä, tehostaen näin koko toimitusketjun toimintaa. Koneoppimisen avulla Volkswagen pystyy analysoimaan laajoja tietomääriä ja tunnistaa optimaaliset toimittajat, mikä parantaa hankintaprosessin nopeutta ja tarkkuutta. Tämä edistää operatiivista tehokkuutta ja tukee yrityksen kykyä reagoida nopeasti markkinoiden muutoksiin (Schroeder & Lodemann, 2021).

DHL hyödyntää koneoppimista "Supply Watch" -järjestelmässään, joka monitoroi toimitusketjun riskejä reaaliajassa yli 140 eri riskikategorian osalta. Järjestelmä hyödyntää muun muassa IoT-laitteista ja skannaustiedoista kerättyä tietoa, sekä päivitettyjä sää- ja liikennetietoja. Koneoppimisalgoritmit analysoivat näitä tietoja ja ennustavat potentiaalisia häiriöitä, mahdollistaen nopeat korjaavat toimenpiteet. Tämä parantaa toimitusketjun läpinäkyvyyttä ja ennustettavuutta, sekä vähentää toimitushäiriöiden vaikutuksia. Samalla DHL:n asiakastyytyväisyys paranee, kun se pystyy informoimaan asiakkaitaan muutoksista aikaisessa vaiheessa (Schroeder & Lodemann, 2021).

Näistä tosielämän esimerkeistä sekä tutkimuksista voidaan päätellä, että koneoppiminen soveltuu hyvin monenlaisiin riskienhallinnan tehtäviin useilla eri toimialoilla. Esimerkit todistavat koneoppimisen vahvuuden erityisesti sen kyvyssä ennustaa ja ennakoita riskejä reaaliaikaisesti, millä mahdollistetaan yritysten proaktiivinen lähestymistapa mahdollisten riskien minimoimiseksi. Koneoppimisen avulla pystytään näin parantamaan huomattavasti toimitusketjun kestävyyttä, resilienssiä sekä ketteryyttä, minkä avulla voidaan saavuttaa selkeää kilpailuetua (Aljohani, 2023; Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021).

4.1.2 Koneoppimisen haasteet ja rajoitukset toimitusketjun riskienhallinnassa

Vaikka koneoppiminen tarjoaa merkittäviä hyötyjä toimitusketjun riskienhallintaan, sen kehittyminen on vielä alkutekijöissään alalla. Koneoppimisen käytännön sovelluksista toimitusketjujen riskienhallintaan on tehty vain vähän tutkimusta. Tämä on johtanut siihen, että alalle ollaan edelleen tietämättömiä koneoppimisen tarkasta potentiaalista toimitusketjujen alalla ja erityisesti riskienhallinnassa (Baryannis ym., 2018, 2019; Brintrup ym., 2020; Schroeder & Lodemann, 2021). Seuraavaksi käsittelemme alan kirjallisuuden pohjalta haasteita ja rajoituksia liittyen koneoppimisen hyödyntämiseen toimitusketjun riskienhallinnassa.

Ensimmäinen ongelma on niin kutsuttu luokan epätasapaino (engl. class imbalance), jossa häiriintyneiden tilausten määrä on huomattavasti pienempi kuin onnistuneiden tilausten. Tämä luokan epätasapaino on yleinen ongelma koneoppimisessa. Se vaikeuttaa koneoppimismallien koulutusta ja heikentää niiden kykyä tunnistaa ja ennustaa harvinaisia tapahtumia, mikä voi johtaa siihen, että mallit eivät pysty reagoimaan riskeihin toimitusketjussa. Esimerkiksi harvinaiset laatuongelmat tuotantoprosessissa

voivat jäädä koneoppimismalleilta tunnistamatta, jos suurin osa tuotannosta kulkee ongelmitta, mikä johtaa mallien ennakoivan kyvyn heikentymiseen poikkeavien tapahtumien suhteen (Baryannis ym., 2019; Brintrup ym., 2020).

Toinen ongelma liittyy relevantin datan saatavuuteen ja laatuun. Tehokas koneoppimisen hyödyntäminen edellyttää korkealaatuista ja kattavaa dataa. Toimitusketjujen riskit ovat sen monipuolisen ympäristön vuoksi haastavia ennustaa. Riskien ilmentymiseen ja vaikutuksiin vaikuttavat useat sisäiset ja ulkoiset muuttujat. Jotta riskejä voidaan hallita tehokkaasti koneoppimisen avulla, näistä molemmista on oltava saatavilla kattavaa ja reaaliaikaista dataa. Tietoon perustuvat mallit, kuten koneoppiminen, johtavat usein virheellisiin tuloksiin, jos käytettävissä oleva data on liian rajallista. Usein yritykset kohtaavat vaikeuksia varsinkin ulkoisen datan hankinnassa, mikä rajoittaa mallien kykyä ennustaa häiriöitä kattavasti (Baryannis ym., 2019; Brintrup ym., 2020; Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021; Tirkolae ym., 2021).

Kolmas ongelma koneoppimisen hyödyntämiseen liittyen on ”dimensionaalisuuden kirous”. Tällä tarkoitetaan muuttujien suurta lukumäärää havaintojen määrään verrattuna. Tämä tarkoittaa, että yksittäisten muuttujien ja havaintojen välillä olevat yhteydet ovat heikkoja, mikä vaikeuttaa tilastollisesti merkittävien päätelmien tekemistä ja mallin yleistettävyyttä. Varsinkin toimitusketjun monimutkaisessa ympäristössä dimensionaalisuuden kirous on yleinen ongelma (Brintrup ym., 2020).

Neljäntenä ongelmana käsitellään koneoppimisen vaatimien resurssien tuottamaa haastetta. Koneoppimismallien kehittäminen, implementointi, ylläpito ja päivittäminen vaativat erikoistunutta teknistä osaamista. Monissa yrityksissä voi olla resurssien tai tietotaidon puutetta, mikä estää edistyneiden koneoppimismallien käytön. Lisäksi koneoppimismallien tehokkuus riippuu niiden kyvystä pysyä ajan tasalla muuttuvien olosuhteiden keskellä. Mallien jatkuva päivitys on välttämätöntä, ja se vaatii jatkuvaa seurantaa ja resursseja, jotta ennustemallit säilyvät relevantteina ja hyödyllisinä. Nämä panostukset ovat kalliita, ja vaativat paljon aikaa ja sitoutumista (Aljohani, 2023; Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021; Tirkolae ym., 2021; Toorajipour ym., 2021).

Seuraavana käsiteltävä ongelma liittyy tietoturvaan ja -suojaan. Toimitusketjuun liittyvien tietojen saatavuus kärsii usein huolenaiheista, jotka liittyvät tietoturvakysymyksiin. Sidosryhmät ovat helposti haluttomia jakamaan yksityiskohtaisia

tietoja edes toimitusketjukumppaneilleen. Suojatun datan jakaminen, tallentaminen ja kerääminen on ongelma, johon on tärkeää löytää luotettavia ratkaisuja. Tässä on kuitenkin nähty nopeaa kehitystä viime vuosina, kun esimerkiksi lohkoketjuteknologiat yleistyvät (Aljohani, 2023; Baryannis ym., 2018; Deiva Ganesh & Kalpana, 2022; Schroeder & Lodemann, 2021; Tirkolae ym., 2021; Toorajipour ym., 2021).

Viimeisenä haasteena käsitellään koneoppimismallien antamien tulosten tarkkuuden ja tulkittavuuden tasapainoa. Vaikka nykyaikaiset koneoppimismallit voivat tarjota erittäin tarkkoja ennusteita, niiden monimutkaisuus voi vaikeuttaa tulosten tulkintaa. Tämä tarkoittaa, että joskus tulkittavuuden ja suorituskyvyn välillä on tehtävä kompromisseja. Tulkittavuuden painottaminen tuloksissa voi alentaa ennustetarkkuutta, mikä voi olla haaste päätöksenteossa (Baryannis ym., 2019).

Nämä haasteet ja rajoitukset osoittavat, että koneoppimisen soveltaminen toimitusketjun riskienhallintaan vaatii huolellista suunnittelua, resursseja ja jatkuvaa kehitystä. Ymmärryksen syventäminen näistä rajoitteista auttaa yrityksiä valmistautumaan koneoppimisen integroimiseen osaksi riskienhallintaprosessia.

5 Yhteenveto ja johtopäätökset

Tämä tutkielma on käsitellyt koneoppimisen soveltamista toimitusketjun riskienhallinnassa. Tutkielman tavoitteena oli selvittää, kuinka koneoppiminen soveltuu toimitusketjun riskienhallintaan, mitä hyötyjä koneoppimisesta saadaan toimitusketjun riskienhallinnassa, sekä mitä haasteita ja rajoituksia koneoppimisen soveltamisessa toimitusketjun riskienhallinnassa on. Tutkielmassa tarkasteltiin toimitusketjujen riskienhallintaa, koneoppimista, sekä koneoppimisen roolia toimitusketjun riskienhallinnassa käyttäen alaan liittyviä tutkimuksia ja kirjallisuutta. Tutkimuskysymyksinä tutkielmassa käytettiin seuraavia kysymyksiä:

- 1) Miten koneoppimista voidaan hyödyntää toimitusketjun riskienhallinnassa?
- 2) Mitkä ovat koneoppimisen käytön haasteet ja rajoitukset toimitusketjun riskienhallinnassa?

Koneoppiminen on osoittautunut merkittäväksi apuvälineeksi toimitusketjujen riskienhallinnassa, tarjoten keinoja tunnistaa, arvioida ja hallita riskejä ennakoivasti ja reaaliaikaisesti. Koneoppiminen mahdollistaa monimutkaisten ja suurten datamäärien käsittelyn, tunnistaa kuvioita ja trendejä, joita ei perinteisillä menetelmillä pystytä havaitsemaan. Tämän avulla yritykset voivat siirtyä reaktiivisesta riskienhallinnasta ennakoivaan ja proaktiiviseen lähestymistapaan (Aljohani, 2023).

Koneoppimisen soveltaminen mahdollistaa myös tarkemmat ennusteet, jotka auttavat yrityksiä valmistautumaan potentiaalsiin häiriöihin ja lieventämään niiden vaikutuksia jo ennen niiden realisoitumista (Deiva Ganesh & Kalpana, 2022). Näin yritykset pystyvät välttymään merkittävilta tappioilta. Koneoppimista hyödyntämällä yritykset voivat parantaa toimitusketjunsä kestävyyttä, resilienssiä sekä ketteryyttä, minkä avulla voidaan saavuttaa merkittävää kilpailuetua.

Tutkielmasta selviää, että koneoppimista voidaan hyödyntää toimitusketjun riskienhallinnassa monin eri tavoin. Koneoppiminen mahdollistaa ennakoivien toimenpiteiden suunnittelun ja toteutuksen, parantaa päätöksenteon nopeutta ja tarkkuutta, ja mahdollistaa joustavamman reagoinnin muuttuviin markkinaolosuhteisiin. Koneoppimisen avulla voidaan tunnistaa riskejä aikaisemmin ja ennustaa niiden vaikutuksia tarkemmin, mikä auttaa vähentämään toimitusketjujen haavoittuvuutta ja parantamaan niiden resilienssiä (Baryannis ym., 2018).

Kuitenkin koneoppimisen soveltamiseen toimitusketjun riskienhallinnassa liittyy myös haasteita. Datan laatu ja saatavuus, koneoppimismallien monimutkaisuus, teknisen osaamisen vaatimukset ja tietoturvakysymykset ovat keskeisiä esteitä, jotka voivat rajoittaa koneoppimisen tehokasta käyttöä. Lisäksi on tärkeää varmistaa, että koneoppimismallit ovat jatkuvasti ajan tasalla ja niitä ylläpidetään asianmukaisesti, jotta ne pysyvät tehokkaina ja relevantteina muuttuvissa toimintaympäristöissä.

Relevantin datan turvallinen kerääminen on yksi keskeisiä koneoppimisen ongelmia tällä hetkellä. Siksi yritysten tulisikin pyrkiä kehittämään tiedonkeruuprosessejaan. On suositeltavaa, että yritykset tekisivät yhteistyötä toimitusketjun eri osapuolten kanssa, jotta saataville tulee kattavampaa ja monipuolisempaa dataa. Lisäksi yritysten tulisi pyrkiä jakamaan tietojaan toimitusketjun riskienhallinnan tutkijoiden kanssa, jotta alalla voidaan kehittää entistä tehokkaampia menetelmiä riskien ennakointiin ja hallintaan.

Koneoppimisen hyödyntäminen toimitusketjuissa ja tutkimukset alalla yleistyvät nopeaa vauhtia. Tulevaisuudessa voidaankin odottaa enemmän käytännön tutkimusta aiheesta, kun enemmän yrityksiä omaksuu koneoppimisen teknologiaa toimitusketjuihinsa. Tulevaisuuden tutkimuksilta odotetaan erityisesti valvomattomien menetelmien hyödyntämisen tarkastelua ja optimointia, millä on suuri potentiaali toimitusketjun riskienhallinnan tehostamisessa.

Lähteet

- Aljohani, A. (2023). Predictive Analytics and Machine Learning for Real-Time Supply Chain Risk Mitigation and Agility. *Sustainability (Basel, Switzerland)*, *15*(20), 15088-.
<https://doi.org/10.3390/su152015088>
- Baryannis, G., Dani, S., & Antoniou, G. (2019). Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. *Future generation computer systems*, *101*, 993–1004. <https://doi.org/10.1016/j.future.2019.07.059>
- Baryannis, G., Validi, S., Dani, S., & Antoniou, G. (2018). Supply chain risk management and artificial intelligence: State of the art and future research directions. *International journal of production research*, *57*(7), 2179–2202.
<https://doi.org/10.1080/00207543.2018.1530476>
- Behzadi, G., O’Sullivan, M. J., Olsen, T. L., & Zhang, A. (2018). Agribusiness supply chain risk management: A review of quantitative decision models. *Omega (Oxford)*, *79*, 21–42.
<https://doi.org/10.1016/j.omega.2017.07.005>
- Brintrup, A., Pak, J., Ratiney, D., Pearce, T., Wichmann, P., Woodall, P., & McFarlane, D. (2020). Supply chain data analytics for predicting supplier disruptions: A case study in complex asset manufacturing. *International Journal of Production Research*, *58*(11), 3330–3341.
<https://doi.org/10.1080/00207543.2019.1685705>
- Cagliano, A. C., De Marco, A., Grimaldi, S., & Rafele, C. (2012). An integrated approach to supply chain risk analysis. *Journal of Risk Research*, *15*(7), 817–840.
<https://doi.org/10.1080/13669877.2012.666757>
- Christopher, M., & Peck, H. (2004). Building the Resilient Supply Chain. *The International Journal of Logistics Management*, *15*(2), 1–14.
<https://doi.org/10.1108/09574090410700275>

- Deiva Ganesh, A., & Kalpana, P. (2022). Future of artificial intelligence and its influence on supply chain risk management – A systematic review. *Computers & industrial engineering*, 169, 108206. <https://doi.org/10.1016/j.cie.2022.108206>
- Fahimnia, B., Tang, C. S., Davarzani, H., & Sarkis, J. (2015). Quantitative models for managing supply chain risks: A review. *European Journal of Operational Research*, 247(1), 1–15. <https://doi.org/10.1016/j.ejor.2015.04.034>
- Garvey, M. D., Carnovale, S., & Yenyurt, S. (2015). An analytical framework for supply network risk propagation: A Bayesian network approach. *European Journal of Operational Research*, 243(2), 618–627. <https://doi.org/10.1016/j.ejor.2014.10.034>
- Gurtu, A., & Johny, J. (2021). Supply Chain Risk Management: Literature Review. *Risks*, 9(1), Article 1. <https://doi.org/10.3390/risks9010016>
- Heckmann, I., Comes, T., & Nickel, S. (2015). A critical review on supply chain risk—Definition, measure and modeling. <https://doi.org/10.1016/j.omega.2014.10.004>
- Ho, W., Zheng, T., Yildiz, H., & Talluri, S. (2015). Supply chain risk management: A literature review. *International Journal of Production Research*, 53(16), 5031–5069. <https://doi.org/10.1080/00207543.2015.1030467>
- Janiesch, C., Zscheck, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science (American Association for the Advancement of Science)*, 349(6245), 255–260. <https://doi.org/10.1126/science.aaa8415>
- Juttner, U. (2005). Supply chain risk management: Understanding the business requirements from a practitioner perspective. *The International Journal of Logistics Management*, 16(1), 120–141. <https://doi.org/10.1108/09574090510617385>
- Kaplan, J. (2016). *Artificial Intelligence: What Everyone Needs to Know*R. Oxford University Press.

- Kleindorfer, P. R., & Saad, G. H. (2005). Managing Disruption Risks in Supply Chains. *Production and Operations Management*, 14(1), 53–68. <https://doi.org/10.1111/j.1937-5956.2005.tb00009.x>
- Lambert, D. M. (2008). *Supply chain management: Processes, partnerships, performance* (3. ed.). Supply Chain Management Institute.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature (London)*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Libbrecht, M. W., & Noble, W. S. (2015). Machine learning applications in genetics and genomics. *Nature Reviews. Genetics*, 16(6), 321–332. <https://doi.org/10.1038/nrg3920>
- Littman, M. L. (2015). Reinforcement learning improves behaviour from evaluative feedback. *Nature (London)*, 521(7553), 445–451. <https://doi.org/10.1038/nature14540>
- Lockamy, A., & McCormack, K. (2009). Examining Operational Risks in Supply Chains. *Supply Chain Forum*, 10(1), 2–14. <https://doi.org/10.1080/16258312.2009.11517204>
- Manuj, I., & Mentzer, J. T. (2008). Global supply chain risk management strategies. *International Journal of Physical Distribution & Logistics Management*, 38(3), 192–223. <https://doi.org/10.1108/09600030810866986>
- Moon, D., & Krahel, J. P. (2020). Continuous Risk Monitoring and Assessment: New Component of Continuous Assurance. *Journal of Emerging Technologies in Accounting*, 17(2), 173–200. <https://doi.org/10.2308/JETA-18-01-09-1>
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.
- Schroeder, M., & Lodemann, S. (2021). A Systematic Investigation of the Integration of Machine Learning into Supply Chain Risk Management. *Logistics*, 5(3), 62. <https://doi.org/10.3390/logistics5030062>
- Shameer, K., Johnson, K. W., Glicksberg, B. S., Dudley, J. T., & Sengupta, P. P. (2018). Machine learning in cardiovascular medicine: Are we there yet? *Heart (British Cardiac Society)*, 104(14), 1156–1164. <https://doi.org/10.1136/heartjnl-2017-311198>

- Sreedevi, R., & Saranga, H. (2017). Uncertainty and supply chain risk: The moderating role of supply chain flexibility in risk mitigation. *International Journal of Production Economics*, 193, 332–342. <https://doi.org/10.1016/j.ijpe.2017.07.024>
- Statista (2022) Artificial intelligence (AI) adoption rate in supply chain and manufacturing businesses worldwide in 2022 and 2025. <https://www.statista.com/statistics/1346717/ai-function-adoption-rates-business-supply-chains/>
- Tang, C., & Tomlin, B. (2008). The power of flexibility for mitigating supply chain risks. *International Journal of Production Economics*, 116(1), 12–27. <https://doi.org/10.1016/j.ijpe.2008.07.008>
- Tirkolaee, E. B., Sadeghi, S., Mooseloo, F. M., Vandchali, H. R., & Aeini, S. (2021). Application of Machine Learning in Supply Chain Management: A Comprehensive Overview of the Main Areas. *Mathematical Problems in Engineering*, 2021, 1–14. <https://doi.org/10.1155/2021/1476043>
- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P., & Fischl, M. (2021). Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research*, 122, 502–517. <https://doi.org/10.1016/j.jbusres.2020.09.009>
- Tummala, R., & Schoenherr, T. (2011). Assessing and managing risks using the Supply Chain Risk Management Process (SCRMP). *Supply Chain Management*, 16(6), 474–483. <https://doi.org/10.1108/13598541111171165>
- Usama, M., Qadir, J., Raza, A., Arif, H., Yau, K. A., Elkhatib, Y., Hussain, A., & Al-Fuqaha, A. (2019). Unsupervised Machine Learning for Networking: Techniques, Applications and Research Challenges. *IEEE Access*, 7, 65579–65615. <https://doi.org/10.1109/ACCESS.2019.2916648>

- van Wyk, J., & Baerwaldt, W. (2005). External Risks and the Global Supply Chain in the Chemicals Industry. *Supply Chain Forum*, 6(1), 2–15.
<https://doi.org/10.1080/16258312.2005.11517135>
- Wagner, S. M., & Bode, C. (2006). An empirical investigation into supply chain vulnerability. *Journal of Purchasing and Supply Management*, 12(6), 301–312.
<https://doi.org/10.1016/j.pursup.2007.01.004>
- Wichmann, P., Brintrup, A., Baker, S., Woodall, P., & McFarlane, D. (2020). Extracting supply chain maps from news articles using deep neural networks. *International Journal of Production Research*, 58(17), 5320–5336.
<https://doi.org/10.1080/00207543.2020.1720925>