



**KONEOPPIMISEN HYÖDYNTÄMINEN MATERIAALIVIRTOJEN SUUNNITTE-  
LEMISESSÄ**

**Utilization of machine learning in material flow planning**

Kandidaatintyö

Lappeenrannan–Lahden teknillinen yliopisto LUT

Tuotantotalouden kandidaatintyö

2022

Jonas Koskula

Tarkastaja: Yliopisto-opettaja Annastiina Rintala

## TIIVISTELMÄ

Lappeenrannan–Lahden teknillinen yliopisto LUT

LUT School of Engineering Science

Tuotantotalous

Jonas Koskula

### **Koneoppimisen hyödyntäminen materiaalivirtojen suunnittelemisessa.**

Tuotantotalouden kandidaatintyö

2022

40 sivua ja 9 kuvaa

Tarkastaja: Yliopisto-opettaja Annastiina Rintala

Avainsanat: Toimitusketjun hallinta, koneoppiminen, neuroverkko, materiaalivirta

2000-luvulla suunnattomasti kasvanut datan määrä ja tietokoneiden tietojenkäsittelytehon suuri kasvu on lisännyt kiinnostusta koneoppimismenetelmiä kohtaan. Yhä useammat toimitusketjut hyödyntävät koneoppimista toimitusketjujen osa-alueissaan optimoidakseen materiaalivirtojensa suunnittelua. Tässä kandidaatintyössä tavoitteena on selvittää, miten koneoppimista voidaan hyödyntää toimitusketjujen materiaalivirtojen suunnittelussa.

Työn alussa perehdytään toimitusketjun hallinnan keskeisimpiin käsitteisiin, toimintoihin ja siihen, miten niissä hoidetaan materiaalivirtojen suunnitteluprosesseja. Sen jälkeen työssä keskitytään koneoppimisen teoriaan tarkemmin ja selvitetään, minkälaisia koneoppimismenetelmiä toimitusketjuissa voidaan hyödyntää. Työssä perehdytään myös koneoppimisen hyödyntämiseen liittyviin mahdollisiin haasteisiin. Lopuksi työssä selvitetään, miten koneoppimismenetelmiä voitaisiin hyödyntää toimitusketjujen materiaalivirtojen suunnittelussa ja minkälaisia hyötyjä se voi niille tuoda.

Tutkimustulokset osoittavat, että koneoppimisen mallit pystyvät oikein käytettyinä tehostamaan materiaalivirtojen suunnittelua, ja siten vähentämään kustannuksia ja nopeuttamaan läpimenoaikoja toimitusketjussa.

# SISÄLLYSLUETTELO

## Tiivistelmä

<b>1</b>	<b>Johdanto</b> .....	<b>3</b>
1.1	Tavoitteet, rajaukset & tutkimuskysymykset .....	3
1.2	Työn toteutus ja rakenne .....	4
<b>2</b>	<b>Toimitusketjun hallinta</b> .....	<b>6</b>
2.1	Kysynnän suunnittelu .....	6
2.2	Varastonhallinta .....	7
2.3	Jakelu .....	9
<b>3</b>	<b>Koneoppiminen</b> .....	<b>11</b>
3.1	Koneoppimisen oppimismallit .....	11
3.2	Koneoppimisen oppimismetodit .....	14
3.2.1	Neuroverkko .....	15
3.2.2	Päätöspuut .....	16
3.2.3	K-means algoritmi .....	17
3.3	Koneoppimisen haasteet .....	18
<b>4</b>	<b>Koneoppimisen soveltaminen materiaalivirtojen suunnittelussa</b> .....	<b>21</b>
4.1	Kysynnän suunnittelu .....	21
4.2	Varastonhallinta .....	23
4.3	Jakelu .....	24
<b>5</b>	<b>Johtopäätökset</b> .....	<b>28</b>
	<b>Lähteet</b> .....	<b>30</b>

# 1 Johdanto

Koneoppiminen on alkanut vaikuttaa lähes kaikkiin toimialoihin ja se on ottanut suurimmat askeleensa 2000-luvulla. Kasvava datan määrä ja tietokoneiden tietojenkäsittelyteho ovat vauhdittaneet koneoppimisen ja tekoälyn saamaa suosiota. Datan saatavuuden lisääntyminen ja tietokoneiden laskentatehon kasvu ovat mahdollistaneet uusien koneoppimismenetelmien syntyminen. Ajatus siitä, että tietokone pystyy ihmisen tavoin oppimaan abstrakteja käsitteitä datasta ja soveltamaan niitä sille tuntemattomiin tilanteisiin ei ole kuitenkaan uusi, vaan se on ollut olemassa ainakin 1950-luvulta lähtien, jolloin ensimmäiset neuroverkot kehitettiin. (Badillo, Banfai & Birzele 2020)

Tiedon määrän räjähdysmäinen kasvu on pakottanut yritykset kehittämään ja ottamaan käyttöön uusia teknologioita, jotta ne pystyvät hyödyntämään aiemmin mainittuja suuria tietomääriä nopeasti ja tehokkaasti. Tekoälymenetelmät ovat sopivimpia menetelmiä vastaamaan tähän dataan liittyvään haasteeseen. Koneoppimista käytetään laajalti tänä päivänä toimitusketjujen eri osa-alueiden materiaalivirtojen suunnittelemisessa ja yritykset etsivät jatkuvasti uusia tapoja hyödyntää koneoppimista toimintojensa optimoimisessa. Hyödyntämällä koneoppimismenetelmiä materiaalivirtojen suunnittelemisessa, toimitusketjut kykenevät tarkasti ennustamaan niiden tulevaisuuden materiaalivirtoja ja vähentämään varastointikustannuksiaan, joista molemmat ratkaisevat monia toimitusketjujen ongelmia. (Tirkolae, Sadeghi, Mooseloo, Vandchali & Aeni 2021; Badillo et al. 2020)

## 1.1 Tavoitteet, rajaukset & tutkimuskysymykset

Koneoppimisen merkitys yritysten työkaluna kasvaa jatkuvasti, mikä antaa tälle kandidaatintyölle oivan mahdollisuuden selvittää, millä tavoin toimitusketjut hyödyntävät koneoppimista materiaalivirtojen hallitsemisessa. Työn tavoitteena on, että

lukija saa konkreettisemmän kuvan koneoppimisesta ja miten sitä voidaan fiksumasti hyödyntää toimitusketjuissa.

Koneoppimisen laajan soveltuvuuden takia työ on rajattu koskemaan ainoastaan toimitusketjujen kysynnän suunnittelua, varastonhallintaa ja jakelua. Nämä kolme toimitusketjun osa-aluetta valittiin, koska lähes kaikki yritysten materiaalivirroista liikkuu niiden ansiosta. Tämän kandidaatintyön päätutkimuskysymys on:

*Miten koneoppimista voidaan hyödyntää toimitusketjuissa, erityisesti kysynnän suunnittelussa, varastonhallinnassa ja jakelussa?*

Päätutkimusta tukemaan on valittu 2 apukysymystä, joihin vastaamalla saadaan selville, millaisia koneoppimismetodeja hyödynnetään toimitusketjuissa, sekä millaisia haasteita koneoppimista implementoitaessa kannattaa ottaa huomioon, jotta pääkysymykseen pystytään vastaamaan tarpeeksi kattavasti:

*Millaisia koneoppimismenetelmiä käytetään toimitusketjujen materiaalivirtojen suunnittelussa?*

*Mitä haasteita koneoppimisen hyödyntämiseen liittyy?*

## **1.2 Työn toteutus ja rakenne**

Kandidaatintyö toteutettiin kirjallisuuskatsauksena ja sen tieto pohjautuu aiheeseen liittyvään teoriakirjallisuuteen sekä tutkielmiin. Kandidaatintyö koostuu viidestä luvusta, joista ensimmäinen on johdanto. Työn toinen ja kolmas luku koostuvat työn kannalta olennaisen teorian käsittelystä. Toinen luku koostuu perinteisiin toimitusketjun hallintaan liittyvien osa-alueiden käsittelemisestä. Kolmannessa luvussa käydään läpi teoriaa koneoppimisesta ja tutkielmalle olennaisia koneoppimismenetelmiä. Kappaleessa tutustutaan myös koneoppimisen hyödyntämiseen liittyviin

haasteisiin. Neljännessä luvussa perehdytään koneoppimisen hyödyntämismenetelmiin toimitusketjuissa. Luvussa käydään läpi millaisia hyötyjä koneoppimismetodit voivat tuoda toimitusketjuille. Viimeinen luku 5 koostuu johtopäätöksistä. Luvussa kootaan yhteen työn tutkimuskysymyksien kannalta tärkeimmät havainnot ja, että onko toimitusketjujen kannattavaa hyödyntää tekoälyä.

## 2 Toimitusketjun hallinta

Tässä luvussa tutustutaan toimitusketjun hallinnan osa-alueisiin ja esitellään millaisia menetelmiä käyttämällä toimitusketjujen materiaalivirtojen suunnittelua, on perinteisemmin hoidettu.

### 2.1 Kysynnän suunnittelu

Liiketoiminnan jatkuvasti lisääntyvä globalisaatio on tehnyt kysynnän suunnittelusta ja hallinnasta entistä monimutkaisempaa, koska markkinat ovat suuren kokonsa ja takia monimutkaisempia kuin koskaan (Ashayeri & Lemmes 2006). Kysynnän suunnittelu on liiketoimintaprosessi, joka vaikuttaa kaikkiin toimitusketjun hallinnan osa-alueisiin (Lee 2001). Kysynnän suunnittelun haasteena on tunnistaa markkinoiden kysyntä etukäteen (Ashayeri et al. 2006), mikä tarkoittaa sitä, että päätökset varastojen täydennyksistä täytyy tehdä ennen kuin tiedetään asiakkaan kysyntä määristä yhtään mitään (Stadtler, Kilger & Meyer 2008). Kysynnän ennusteen täytyy olla mahdollisimman tarkka, jotta varastoja ja niihin liittyviä kustannuksia ei kasvateta ilman syytä. Karkea kuukausittainen ennuste ei tarjoa riittävää tukea kysynnän ennustamiselle. Koska kysynnän suunnittelu on hajanainen eri osa-alueilla, siitä tulee entistä monimutkaisempaa. (Ashayeri et al. 2006)

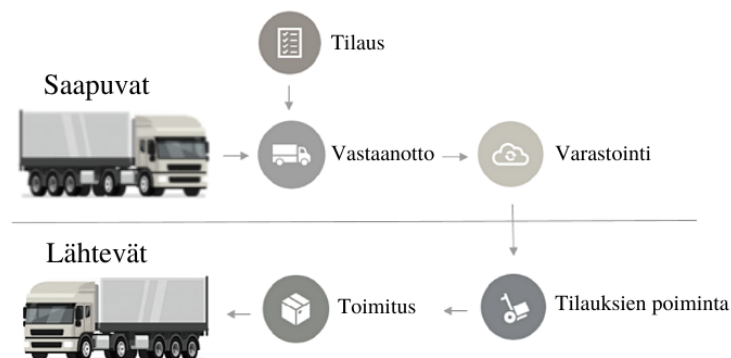
Kysynnän suunnittelu kattaa useita eripituisia ajanjaksoja. Stadtler et al. (2008) mukaan ennusteet suunnitellaan yleisimmin 12–24 kuukauden sisälle. Monissa tilanteissa ennuste voidaan laskea automaattisesti aiemmista asiakastilauksista. Tätä kutsutaan tilastolliseksi ennustamiseksi. Tilastollisessa ennustamisessa käytetään kehittyneitä menetelmiä, joilla luodaan ennusteet monille nimikkeille automaattisesti. (Stadtler et al. 2008) Kysynnän suunnittelun tuoman tuloksen parantamisen kannalta Ashayeri et al. (2006) mukaan noin 50% ennustetarkkuudesta on enemmän haittaa, kuin hyötyä.

Asianmukaisen kysynnän suunnittelun avulla ennustevirhe pienenee ja, kun markkinoiden kehitystä ennakoidaan ajoissa, niin voidaan laatia luotettavampi

myyntisuunnitelma (Ashayeri et al. 2006). Tämän takia yritykset ottavat käyttöön huippuluokan toiminnanohjausjärjestelmiä ja kehittyneitä suunnittelujärjestelmiä kuten APS. Vaikka APS-järjestelmiin liittyviin konsulttipalveluihin on investoitu miljoonia dollareita, kysynnän suunnittelu monimutkaisissa toimitusketjuissa on edelleen jatkuva haaste, joka johtuu markkinoiden tuhansista yksittäisistä tuotteista ja asiakkaista. (Ashayeri et al.; Stadtler et al. 2008)

## 2.2 Varastonhallinta

Varastot saatetaan Ponten (2018) mukaan usein nähdä pelkinä varastointipisteinä, joilla pyritään vastaamaan kysyntään, sekä toimimaan puskurina toimitusketjun eri toimijoiden välillä. Varastojen näkyvyys toimitusketjussa on rajallista ja tiedonkulku hyvin hidasta, mikä johtaa usein siihen, että yritykset pitävät tarpeettoman suuria varastoja. (Ponte 2018) Varastot toimivat toimittajan ja asiakkaan välisten materiaali- virtojen solmukohtina (Ramaa, Subramanya & Rangaswamy 2012). Kuvasta 1 voidaan hahmottaa varaston materiaalivirtoja koskevia perustoimintoja. (Gu, Goetschalckx ja McGinnis 2007).



**Kuva 1:** Toimitusketjun perustoimintoja (Muunneltu lähteestä Gu, Goetschalckx ja McGinnis 2007).

Kuvasta 1 nähdään, että tavaran vastaanottaminen ja lähettäminen ovat varaston rajapintoja sinne saapuvalle ja sieltä lähteville materiaalivirroille. Varastoon saapuvat lähetykset otetaan vastaan, jonka jälkeen ne varastoidaan. Asiakkaan tilauksen saapuessa kerätään oikeat tavarat varastosta ja valmistellaan lähetys



toimitettavaksi tilauksen tehneelle osapuolelle. Materiaalivirtojen suunnitteluun täytyy panostaa varastoissakin, jotta niiden läpimenoaikoja saataisiin lyhennettyä. Läpimenoaikoja voidaan lyhentää optimoimalla varaston toimintoja uusia menetelmiä käyttämällä tai löytämällä pullonkauloja, jotka hidastavat materiaalivirtojen kulkua. Läpimenoaikojen lyheneminen mahdollistaa myös toimitusaikojen lyhenemisen, joka taas vähentää varastoitujen tavaroiden määrää (Interlake Mecalux 2019). Toimitusaikojen lyheneminen lisää asiakastytyvyyttä ja varastotasojen pieneneminen laskee ylimääräisiä varastointikustannuksia.

Nykyisessä erittäin kilpailullisessa liiketoimintaympäristössä yritykset ovat entistä tarkempia omaisuuden tuottamisesta. Varastointikustannuksien minimoimisesta on tullut siis yhä tärkeämpää. Teknologian kehityksen ansiosta varastot ovat ottaneet käyttöön innovatiivisempia menetelmiä kuten varastonhallintajärjestelmiä, jotka optimoivat kuvassa 1 näkyvien tehtävien suorittamista. Varastonhallintajärjestelmä on tietokantapohjainen tietokonesovellus, jonka tarkoituksena on parantaa varastojen tehokkuutta ohjaamalla muun muassa niiden poiskuljetuksia ja ylläpitämällä tarkkoja inventaarioita varastotapahtumista. (Ramaa et al 2012) Automatisoimalla varastoinnin perustoimintoja on saatu vähennettyä varastojen läpimenoasteita. (Ramaa et al. 2012) Varastoja voidaan ohjata ja optimoida myös varastopaikkojen käyttöasteiden reaaliaikaisen tiedon perusteella, jonka mahdollistaa radiotaajuustunnistusteknologian (RFID).

RFID teknologiaa hyödynnetään siten, että toimitusketjussa liikkuviin tavaroihin lisätään tunnistet. Tunnisteilla kiinnitetyt tavarat kirjataan automaattisesti tietokantaan RFID-lukijoilla, kun tavarat lastataan kuorma-autoon tai, kun kuorma puretaan varastoon. RFID teknologian avulla voidaan seurata tehokkaammin materiaalivirtoja (Keller, Thiesse & Fleisch 2014). Tarvittavan datan keräämisen jälkeen tiedot siirretään langattomasti reaaliajassa keskustietokantaan. (Ramaa et al. 2012) Tietokannasta voidaan tarkasti seurata varastotasoja.

## 2.3 Jakelu

Logistiset reititysvaihtoehdot ovat muuttuneet yhä monimutkaisemmiksi, kun tuotteiden, päätöksentekopisteiden sekä maailmanlaajuisten toimittajien ja asiakkaiden määrä on kasvanut (Becker, Illigen, McKelvey, Hülsmann & Windt 2016).

Koska asiakaslähtöisyys on toimitusketjun hallinnan keskeinen osatekijä, niin toimitussuorituskyky on toimitusketjun olennainen mittari. Toimitussuorituskyky on optimaalinen, kun tavarat saapuvat haluttuihin paikkoihin vaadituissa määrissä oikeaan aikaan. Sen vuoksi on tärkeää suunnitella, että missä järjestyksessä tuotteet kuljetaan ja miten. Kuljetuksissa otetaan huomioon muun muassa reittien pituus, nopeus, kustannustehokkuus. (Košíček, Dařena, Malo, Motycka & Tesař 2012) Yleistavoitteena on siis hankintapisteiden ja asiakkaiden välille luotavan yhteyden luominen mahdollisimman alhaisilla kustannuksilla. (Frazelle. 2002 S 171) Toimitusketjuille on siis tärkeää huolehtia niiden vaste- ja toimitusajoista, jotta ne voivat ylläpitää asiakassuhteitaan.

Kuljetusjärjestelmän rakenne riippuu pääasiassa lähetysten koosta, sillä esimerkiksi suuret lähetykset voivat kulkea suoraan lähteestä määränpäähän täysissä kuljetusyksiköissä, esimerkiksi kuorma-autoissa tai konteissa. Pienet lähetykset on yhdistettävä kuljetusverkostoon, jossa yksittäinen lähetykset siirretään kerran tai useita kertoja ja kuljetus katkaistaan uudelleenlastauspaikoissa. Huonosti suunnitellut kuljetukset aiheuttavat lisäkustannuksia yrityksille. Näitä lisäkustannuksia ovat muun muassa ylimääräisestä ajamisesta johtuvat polttoaine- ja työntekijöiden ylityö kustannukset (PurolatorInternational 2020).

Toimitusketjuissa keskitytään näiden reititysongelmien ratkaisemiseen määrittämällä ajoneuvoille optimaaliset reitit ottaen huomioon toiminnalliset rajoitukset kuten aikaikkunat ja reitin pituuden. Reittien suunnittelu auttaa kuljettajia kulkemaan reittejä, jotka maksimoivat kuljettajien tehokkuuden. Näitä ongelmia on vaikea ratkaista manuaalisesti niiden monimutkaisuuden takia, jonka vuoksi yhä useammat yritykset ovat siirtyneet käyttämään reittisuunnittelujärjestelmiä. (Lakshmi 2020)

Reittisuunnittelujärjestelmissä määritetään, missä järjestyksessä valittujen kuljetusajoneuvojen tulisi toimittaa tarvittavat tavaramäärät kysyntäpisteisiin.

Reittisuunnittelujärjestelmät tuovat monia etuja yrityksen asiakkaille, johdolle ja aikatauluttajille. Asiakkaat saavat muun muassa lisää luotettavuutta toimitusaikoihin, kun taas hallinnon ja aikatauluttajien rutiinitehtävien määrät laskevat, joka johtaa työtehtävissä tehtyjen virheiden vähenemiseen. (Knolmayer, Mertens & Zeier 2002)

## 3 Koneoppiminen

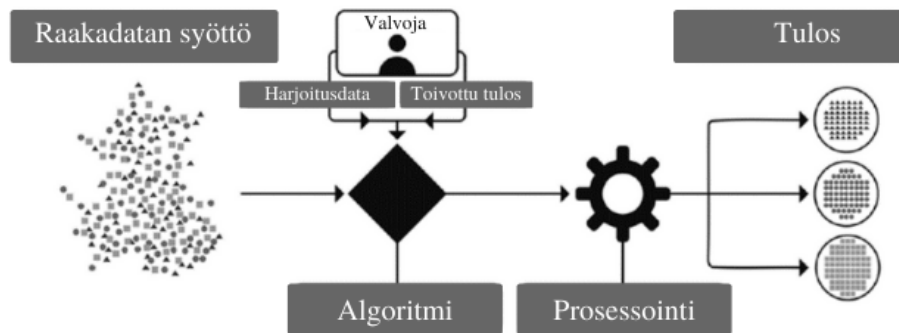
Koneoppiminen on laskenta-algoritmeihin perustuva tekoälyn osa-alue, joka keskittyy tekoälyn oppimisenäkökulmaan (Choi, Coyner, Kalpathy-Cramer, Chiang & Campbell 2020). Koneoppimisen algoritmeja hyödyntämällä tietokoneet voivat käytännössä oppia ilman varsinaista ohjelmointia, joka muistuttaa ihmisen oppimiskäyttäytymistä. Koneoppimisen sanotaankin joissain määrin jäljittelevän ihmisen tapaa oppia tietoa ympäristöstään (Gunjan, Diaz, Cardona & Solanki 2019). Koneoppimisen kyky oppia itsenäisesti on nostattanut sen suosiota työkaluna, joka näkyy uusien käyttömenetelmien jatkuvana ilmaantumisenä (Panesar 2021 69–71). Koneoppimisen avulla järjestelmät kykenevät tunnistamaan olemassa olevasta datasta yhtäläisyyksiä ja ratkaista niihin liittyviä ongelmia (Flach 2012).

Koneoppiminen pitää sisällään monia erilaisia algoritmeja ja tilastollisia malleja, joita käytetään datatieteessä automatisoimaan, ennustamaan ja ratkaisemaan erilaisia ongelmia (Louridas & Ebert 2016). Koneoppimisen hyödyntämisestä on tulossa lähes pakollista yrityksille sen tuoman ongelmanratkaisu- ja automatisaatio mahdollisuuksien myötä, koska ne antavat selvän etulyöntiaseman yrityksen toiminnalle (Gunjan et al. 2019).

Tämän luvun alussa perehdytään kolmeen koneoppimisen päätyyppiin. Päätyypit on jaoteltu sen mukaan, miten niiden oppiminen tapahtuu. Sen lisäksi esitellään työlle keskeisimpiä koneoppimismenetelmiä ja miten ne toimivat. Viimeiseksi käydään läpi minkälaisia haasteita koneoppimisen implementoiminen saattaa aiheuttaa.

### 3.1 Koneoppimisen oppimismallit


Valvottu oppiminen on koneoppimismenetelmistä eniten käytetty tänä päivänä. Sitä kutsutaan valvotuksi oppimiseksi siksi, koska opetuksessa on mukana niin sanotusti valvoja, joka syöttää algoritmille sen kouluttamiseen tarkoitettuja datasettejä, niin kuin kuvasta 2 voidaan huomata.



**Kuva 2:** Valvotun oppimisen prosessi (Muunneltu lähteestä Panesar 2021)

Kuvasta 2 huomataan myös, että valvoja opettajan tavoin välittää algoritmille tiedon halutusta tuloksesta ja ilmoittaa kun tapahtuu mahdollisia virheitä (Choi et al. 2020). Valvotussa oppimisessä tunnetaan siis koko ajan lähtö ja tulo parametrit, joiden perusteella koneoppimisalgoritmi harjoittelee, että mitkä ominaisuudet ja ominaisuuksien yhdistelmät tuottavat tietynlaisen tuloksen. (Zhou & Chen 2018) Kun algoritmi on saavuttanut tarpeeksi hyvän suoriutumistason harjoitusdatan kanssa, niin voidaan sille alkaa syöttämään yrityksen raakadataa, jota se on oppinut jo käsittelemään koulutusvaiheen ansiosta (Brownlee 2016). Algoritmeja koulutetaan suurilla datajoukoilla, mikä mahdollistaa muun muassa todella tarkkojen ennustemallien luomisen. Useimmissa tilanteissa voidaan ajatella, että mitä suurempi datajoukko koneoppimisalgoritmillä on käytössään, niin sen tarkempia tuloksia se kykenee antamaan. Valvotun oppimisen algoritmit kehittyvät myös tarkemmiksi ajan myötä. (Norvig & Russell 2009, s. 695–697) Valvottua oppimista käytetään yleisimmin luokittelu, regressio ja ennustamis- ongelmien ratkaisemiseen.

Valvomaton oppiminen on nimensä mukaisesti valvotun oppimisen vastakohta. Kuvasta 3 voidaan huomata, että valvotussa oppimisessä ei ole valvojaa ja, että oppimisalgoritmi ei saa huomautuksia virheistään. Toisin kuin valvotussa oppimisessä, valvomattomassa oppimisessä ei ole ennalta määriteltyjä oikeita tuloksia, vaan niiden oikeellisuus ja ymmärtäminen jäävät itse algoritmin määriteltäväksi. Valvomattomassa oppimisessä algoritmin tavoitteena on ymmärtää dataa löytämällä siitä erilaisia yhdistelmiä ja rakenteita, jonka takia sitä on hyvä käyttää vaikeasti löydettävien tai ymmärrettävien yhdistelmien etsimiseen.

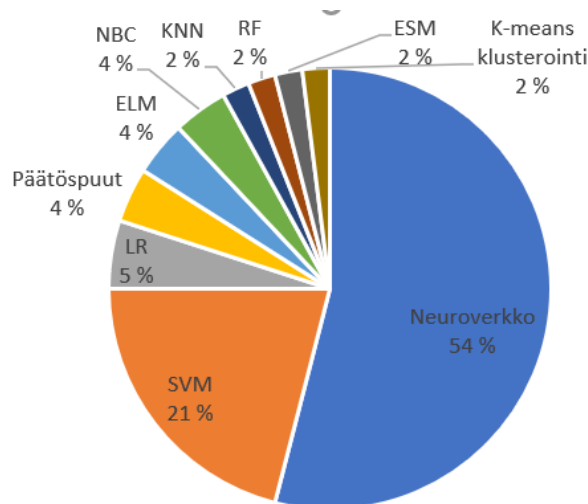


**Kuva 3:** Valvomattoman oppimisen prosessi (Muunneltu lähteestä Panesar 2021)

Valvomattoma oppimista käytetään yleisimmin ryhmittelyyn ja asioiden yhteneväisyyksien etsimiseen liittyvissä ongelmissa. (Panesar 2021) Vahvistusoppiminen, sisältää osia sekä valvotusta, että valvomattomasta oppimisesta (Rebala et al. 2019, s. 21). Se on menetelmä, jossa algoritmin tavoite on määrittelemätön. Oppijalle ei ilmoiteta mihin toimintaan ryhtyä tai onko se tehnyt virhettä, vaan sen sijaan hänen on löydettävä, mikä ponnistus tuottaa maksimaalisen palkkion. (Faria et al. 2010) Vahvistusoppimisessa käytetty data ei sisällä etikettidataa, joka antaisi koneelle palautetta onnistumisesta valvotun oppimisen tapaisesti, vaan se saa palautetta ympäristöstään. Vahvistusoppimisen suurin etu on se, että se ei tarvitse ennalta määriteltyä mallia ympäristöstä. (Oliveira & Rana 2013)

### 3.2 Koneoppimisen oppimismetodit

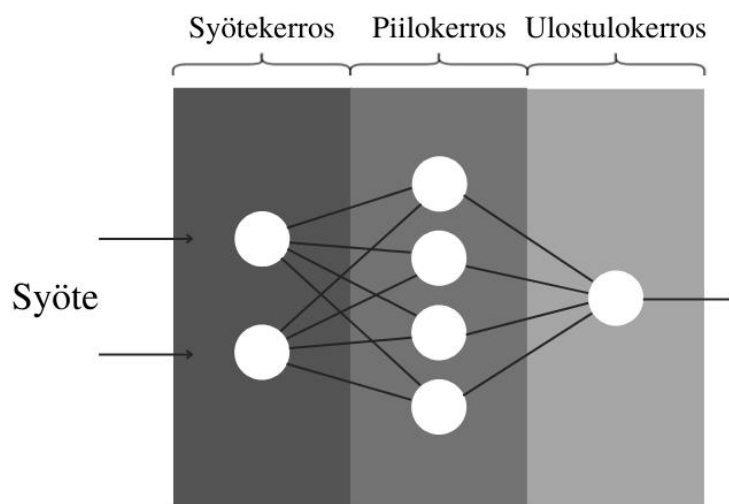
Aiemmassa kappaleessa mainitut koneoppimisen oppimismallit pitävät sisällään monia erilaisia koneoppimismenetelmiä, jotka ryhmitellään niiden tehtävien ratkaisutaitojen mukaan. Ni, Xiao & Limin (2020) tutkimuksen mukaan kaikista koneoppimismenetelmistä vain noin kymmentä sovelletaan toimitusketjuissa säännöllisesti. Kuva 4 auttaa hahmottamaan kuinka Ni et al. (2020) luetteloi koneoppimisen toimitusketjuissa, yleisimmin käytetyt tutkimukset jakautuvat koneoppimis metodeittain. Neuroverkot ovat nähtävästi eniten tutkittu ja sovellettu menetelmä. Neuroverkkojen todella suurta määrä selittää osittain se, että usein erilaisten koneoppimismenetelmien tuloksia verrataan neuroverkkojen saamiin tuloksiin. (Ni et al. 2020)



**Kuva 4:** Koneoppimismetodien suosio toimitusketjuissa (Muunneltu lähteestä Ni, Xiao & Limin 2020)

### 3.2.1 Neuroverkko

Keinotekoiset neuroverkot ovat biologisten neuroverkkojen inspiroimia koneoppimismalgoritmeja (Choi et al. 2020). Neuroverkkojen tehtävänä on simuloida ihmisen aivoja oppimistilanteessa (Singh, Shukla & Mishra 2018). Neuroverkot kykenevät inhimillistä ajattelua hyödyntämällä käsittelemään suuria tietomääriä analyysien suorittamiseksi (Akabane et al 2019). Kuvassa 5 näkyvät pallot kuvaavat neuroverkkojen sisältämiä keinotekoisia neuroneita, jotka kykenevät kommunikoivat toistensa kanssa. Neuronien välisiä yhteyksiä painotetaan niiden tuottamien tulosten perusteella. Yhteyksien painoarvot ovat alkuvaiheessa yleensä satunnaisia, mutta ne optimoidaan oppimisvaiheen aikana, jolloin muutoksia tehdään testituloksien antamien virheiden perusteella, vertailemalla niitä jo tunnettuihin oikeisiin tuloksiin (Choi et al. 2020; Akabane et al 2019). Neuroverkkoa voidaan koulutuksen jälkeen soveltaa tapauksiin, joissa tulos ei ole tiedossa. Jokainen verkon sisällä oleva neuroni on



**Kuva 5:** Neuroverkon prosessi (Muunneltu lähteestä Choi et al. 2020)

yksinkertainen prosessointiyksikkö, jossa suoritetaan peruslaskutoimituksia yhden tai useamman syötteen käsittelemiseksi ja merkityksellisten tulosten tuottamiseksi (Brown 2021).

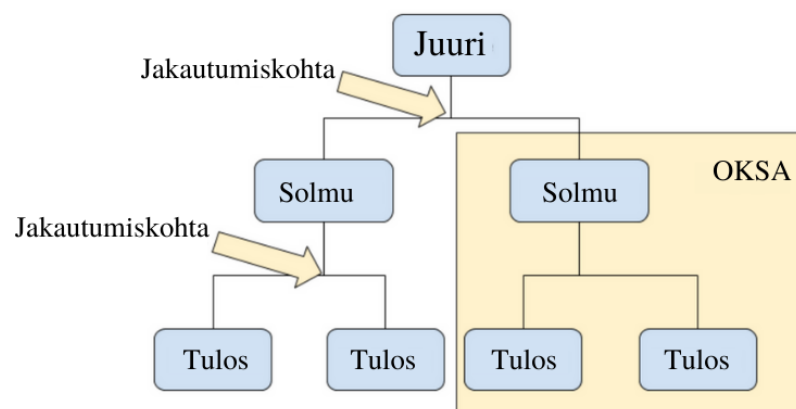
Kuvassa 5 nähdään, että neuroverkot koostuvat erilaisista kerroksista. Kerroksia ovat syöttökerros, piilokerrokset ja lähtökerros. Syöttökerros koostuu joukosta



neuroneja, jolle syötetään syötedata. Piilokerroksien ja niiden neuronien määrät vaihtelevat (IBM 2017). Niiden lukumäärät määritetään yleensä kokeile ja erehdy - menetelmällä lisäämällä tai vähentämällä piilokerroksen ja neuronien määrää koulutuksen aikana. Ensimmäiseen kerrokseen syötetty data kulkee piilokerroksien läpi, jolloin sitä kerrotaan ja lasketaan yhteen monimutkaisilla tavoilla, kunnes se lopulta saapuu täysin muuttuneena neuronien painotettujen syötteiden summana ulostulokerrokseen. (Hardesty 2017)

### 3.2.2 Päätöspuut

Päätöspuut ovat vuokaavioita, jotka esittävät päätöksentekoprosessin luokittelusääntöinä. Sitä käytetään luokittelutarkoituksessa. Päätöspuut alkavat juuresta ja niin kuin kuvasta 6 nähdään, niin ne sisältävät solmuja, jotka pitävät sisällään erilaisia ominaisuuksia. Jokaisella ominaisuudella on 2 etenemis- vaihtoehtoa ja, kun edetään haaraan, joka ei enää jakaudu, niin on päädytty tulokseen. (Panesar 2021) Ongelmasta riippuen päätöspuun solmukohdissa voi olla joko luokkia, todennäköisyyksiä tai regressiossa jatkuvia arvoja. Tyypillisesti syöttötiedot esitetään attribuuttiarvoina ja instanssit lajitellaan ominaisuusarvojen perusteella. (Badillo, Banfai & Birzele 2020)




**Kuva 6:** Päätöspuun prosessi (Muunneltu lähteestä Keboola 2020)

Päätöspuut ovat muihin koneoppimismetodeihin verrattuna todella helppokäyttöisiä, koska hankittu tieto voidaan ilmaista helposti ymmärrettävässä muodossa ja tulokset voidaan ilmaista sääntöjoukkoina. (Cheng, Chen & Lin 2010; Thomassey & Fioraliso 2006) Toisin kuin useammat muut algoritmit päätöspuut toimivat hyvin myös siivoamattoman datan kanssa, joten datan putsaamiseen ei tarvitse käyttää yhtä paljon aikaa, kuin muiden algoritmien kanssa (Keboola 2020). Keskeinen kysymys päätöspuun oppimisessa on, että mitkä solmukohtat tulisi sijoittaa mihinkin paikkaan, jotta saavutetaan parhain tulos.

### **3.2.3 K-means algoritmi**

K-means klusteroinnin tarkoituksena on pyrkiä löytämään aineistosta samankaltaisia ryhmiä (Panesar 2021). Klusterin sisällä olevien datapisteiden täytyy olla samankaltaisia keskenään, koska K-means klusteroinnin päätavoitteena on minimoida pisteiden ja niiden klusterin keskipisteen välisten etäisyyksien summa. K-means algoritmi on painopisteeseen perustuva algoritmi, jonka tavoitteena on, että jokainen klusteri olisi sidottu keskipisteeseen (Pulkit 2019). K-means klusterointi on toistopohjainen algoritmi, jonka prosessi pitää sisällään 5 vaihetta. Ensimmäisessä vaiheessa valitaan, että kuinka moneen klusteriin pisteet halutaan määrittää. Kuvan 7 esimerkki tilanteesta voidaan huomata, että klustereiden määräksi on määritetty 2.



**Kuva 7:** K-means klusteroinnin prosessi (Muunneltu lähteestä Panesar 2021)

Vaiheessa 2 valitaan aineistosta molemmille klustereille satunnaiset keskipisteet, joita kuvassa 7 esittää tähden muotoinen objekti. Kun olemme määritelleet keskipisteet, niin vaiheessa 3 osoitamme jokaisen pisteen sille lähimpään klusterin keskipisteeseen. Kun kaikille pisteille on määritetty klusteri, niin vaiheessa 4 lasketaan vastaperustettujen klustereiden keskipisteet, joka näkyy kuvassa 7 tähden paikan vaihtumisena klusterin keskelle. Prosessin vaiheita 3 ja 4 toistetaan kunnes kaikkien klustereiden keskipisteet pysyvät samoina useiden toistojen jälkeenkin, jolloin algoritmi ei opi enää uusia kuvioita, jolloin koulutus lopetetaan. (Pulkit 2019) K-means algoritmi suoriutuu hyvin esimerkiksi asiakkaiden segmentoimiseen tai samanlaisien dokumenttien yhteen luokitteluun.

### 3.3 Koneoppimisen haasteet

Koneoppimisen toimitusketjuille tuomien monien hyötyjen lisäksi täytyy muistaa koneoppimisen hyödyntämiseen liittyvät haasteet ja rajoitukset.

Ensimmäinen koneoppimisen haasteista liittyy tarvittavan suuren tietomäärän saatavuuteen. Useimpien koneoppimisalgoritmien tehokas toiminta edellyttää suuria

data määriä, jotta ne toimisivat kunnolla. Näiden tarvittavien suurien tietomäärien saatavuus on kuitenkin usein haasteellista. Ongelmien tehokkaasti ratkaisemiseen tarvitaan tyypillisesti tuhansia esimerkkejä, ja monimutkaisiin ongelmiin, kuten kuvan- tai puheentunnistukseen voidaan tarvita miljoonia esimerkkejä. On ratkaisevan tärkeää käyttää harjoitusdataa, joka edustaa niitä ongelmia, joita halutaan ratkaista. Tämä on usein vaikeampaa kuin miltä se kuulostaa, jos datajoukko on liian pieni, niin otoskohinaa, eli sattumasta johtuvaa epäedustavaa dataa esiintyy. Hyvin suuret otokset voivat myös olla ongelmallisia, jos otantamenetelmä on virheellinen. (Géron, 2017, s. 29)

Toinen yleinen haaste koskee koneoppimisalgoritmien kouluttamisessa käytettävän datan heikkoa laatua. Jotta data voitaisiin ryhmitellä tai saada muunnettua näkyviin malleihin, niin koneoppimisalgoritmin on pystyttävä tunnistamaan yhtäläisyyksiä datasta. Tällaiseen ongelmaan törmätään, kun datassa on paljon virheitä tai poikkeavia lukuja. On selvää, että jos harjoitusaineisto on täynnä virheitä, poikkeamia ja kohinaa, on järjestelmän vaikeampi havaita taustalla olevia yhtäläisyyksiä, joka itessään heikentää järjestelmän suorituskykyä. Kohinalla tarkoitetaan esimerkiksi huonolaatuisen mittauksen aiheuttamaa puutteellista dataa. Usein on vaivan arvoista käyttää aikaa harjoitusaineiston puhdistamiseen. Useimmat datatieteilijät käyttävät merkittävän osan ajastaan datan putsaamiseen, koska on järkevämpää käyttää aikaa harjoitusaineiston puhdistamiseen etukäteen, kuin ihmetellä epätarkkojen tuloksien syytä jälkeinpäin. Datan laadun lisäksi on hyvä ottaa huomioon, että järjestelmät eivät suoriudu tehokkaasti, jos harjoitusdatajoukko on liian pieni. Malli ei saa olla liian yksinkertainen eikä liian monimutkainen. Monimutkaiset koneoppimisen mallit havaitsevat hienovaraisia yhtäläisyyksiä datassa, esimerkiksi neuroverkot voivat havaita hienovaraisia yhtäläisyyksiä datassa. Kuitenkin, jos harjoitusjoukko on kohinainen tai liian pieni, niin malli saattaa havaita kuvioita itse kohinassa, joka laskee koneoppimismallien tehokkuutta. (Géron 2019)

Kolmas haaste on oikeanlaisen koneoppimismenetelmän valitseminen erilaisten ongelmien ratkomiseksi, koska ei ole yksittäistä menetelmää, joka toimisi aina paremmin kuin muut menetelmät. (James, Witten, Hastie & Tibshirani 2013) Tämän takia on yleistä, että tutkielmissa perehdytään monen erilaisen koneoppimisen metodin tuloksiin, jotta löydettäisiin parhaiten kyseiseen ongelmaan toimiva metodi. Hyvä

esimerkki tästä on Keller et. al. (2014) tutkimus, jossa luokittelu menetelminä käytettiin logistisen regression, päätöspuiden ja keinotekkoisten neuroverkkojen menetelmiä (Keller, Thiesse & Fleisch 2014)

Neljäs koneoppimisen haasteista on huonosti valitusta algoritmista johtuva ylisovittaminen ja alisovittaminen (Géron 2017 s. 22). Ylisovittaminen tarkoittaa sitä, että koneoppimisalgoritmit voivat joskus yleistää tuloksiaan virheellisesti, vaikka malli toimisikin täydellisesti harjoitusdatajoukossa. Koneoppimisalgoritmeilla on siis alttius kehittyä puolueellisiksi tiettyjä kantoja kohtaan. Näin tapahtuu, kun järjestelmän kouluttamiseen tarkoitettu data on ollut liian suppeaa (McKinsey 2017). Ylisovittaminen saattaa myös johtua liian monimutkaisesta mallista, jolloin malli seuraa datan kohinaa tai virheitä liian tarkasti (James et al. 2013, s. 22–23). Alisovittaminen on nimensä mukaisesti ylisovittamisen vastakohta. Alisovittamista tapahtuu, kun koneoppimismalli on liian yksinkertainen oppiakseen tai tunnistaakseen datan taustalla olevaa rakennetta. (Géron, 2017, s. 29)

## **4 Koneoppimisen soveltaminen materiaalivirtojen suunnittelussa**

Toimitusketjujen materiaalivirtojen suunnittelemisen on muuttunut erittäin informaatio painotteiseksi. Informaation hallitsemiseksi kehitetään jatkuvasti uudenlaisia koneoppimista hyödyntäviä algoritmeja, joita on mahdollista hyödyntää toimitusketjujen eri osa-alueissa. Koneoppimisen käyttöönoton yleistyttyä yritykset ovat pystyneet yhä enemmän minimoimaan päätöksentekoon kulutettua aikaa sekä työpanosta. (Carbonneau, Laframboise & Vahidov 2018) Tämän luvun kolmessa kappaleessa käydään läpi, että miten koneoppimista hyödynnetään toimitusketjun kysynnän, varastonhallinnan ja jakelun materiaalivirtojen suunnittelussa.

### **4.1 Kysynnän suunnittelu**

Toimitusketjujen hallinnassa suurin osa suunnittelusta johdetaan kysynnän ja myynnin arvioimisen kautta. Käyttämällä koneoppimisalgoritmeja pystytään parantamaan kysynnän ja optimaalisten varastotarpeiden ennustamisen tarkkuutta. Hyvän kysyntäennusteen laatiminen ei ole yksinkertaista, koska sen tulee toimia kaiken myyntipotentialin arvioinnin pohjana, jolloin arviointijärjestelmästä muotoutuu nopeasti todella monimutkainen. Kovassa kilpailuympäristössä yrityksiä on oltava erittäin tarkkoja kustannuksien, toimitusnopeuden ja varastopolitiikan suhteen, säilyttääkseen kilpailukykyä. (Ning, Lau, Zhao & Wong 2009)

Kysynnän ennustaminen on ratkaisevassa asemassa täydennys toimituksissa, koska yrityksillä on paineita pienentää niiden varastotasoa, niihin liittyvien kustannuksien takia (Ning et al. 2009). Ning et al. tutkimuksessa havaitaan, miten koneoppimismenetelmiä käyttämällä tukkukaupan toimintakustannukset alenivat merkittävästi ja jälleenmyyjien tyytyväisyys nousi. Tutkimuksessa hyödynnetään neuroverkko teknologiaa käyttävää järjestelmää, joka opastaa yritystä siinä, että milloin ja minkä verran tarkoituksenmukaista tavaraa tarvitsee tilata. Järjestelmä on koulutettu 300 päivän vähittäiskauppioiden historiallisella kysyntä datalla. Data syötetään koneoppimisjärjestelmään, jonka jälkeen järjestelmä tuottaa tulevan kysynnän

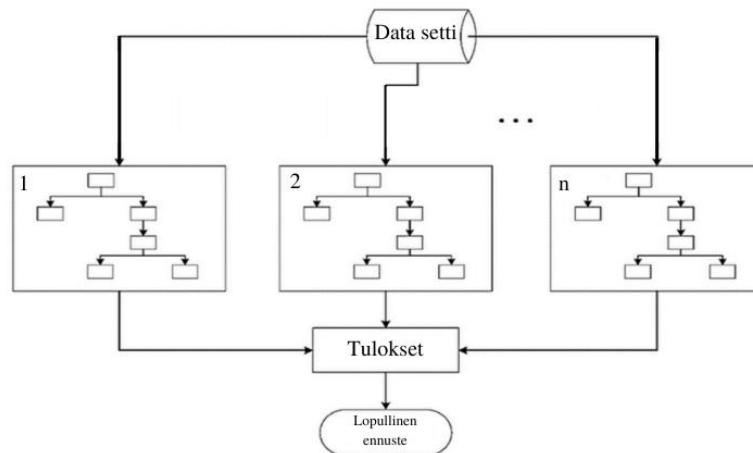
ennusteen. Ning et al. (2009) tutkimuksessa mainitaan, että mitä pidemmälle tulevaisuuteen tutkimuksessa käytetty malli ennustaa, niin sitä suurempi on ennustevirhe. Tutkimuksessa 5 päivän ennusteiden tekeminen tuotti suurimmat toimintakustannuksien säästöt, vähentäen niitä noin 44%. Lyhyeltä tuntuva 5 päivän ennuste toimii hyvin Ning et al. (2009) tutkimuksessa, koska tavarantoimittajat pystyivät toimittamaan tuotteita tukkukauppiaille lähes päivittäin. Kysynnän ennustaminen vaikuttaa eniten yrityksen takaisintilaus- ja varastointikustannuksien pienenemiseen. (Ning et al. 2009) Tutkimuksen perusteella voidaan uskoa, että yritykset voivat tehdä merkittäviä säästöjä toimintakustannuksissaan hyödyntämällä neuroverkkoja ennustamismenetelmissään.

Lu & kao (2016) suorittamassa tutkimuksessa mainitaan, että yksittäisen kysynnän ennustemenetelmän tehokkuutta voidaan parantaa hyödyntämällä useampia koneoppimisen menetelmiä. Lu & Kao mainitsevat tutkimuksessaan, että toimintakustannuksien alenemisen lisäksi kysynnän ennustaminen parantaa yrityksen päätöksenteon tehokkuutta. Tutkimuksessa esitellään datan ryhmittelyyn perustuvaa koneoppimisen kysynnän ennustus järjestelmää. Ryhmittely suoritetaan menetelmän opetusvaiheessa harjoitus datalle käyttämällä K-means algoritmia, jonka tuloksena data muuttuu useiksi hajanaisiksi klustereiksi. Seuraavaksi harjoitusvaiheessa käytetään extreme learning machine (ELM) menetelmää rakentamaan juuri luoduille klusterille niiden omat ELM ennustemallit. (Lu & Kao 2016)

ELM on yhden kerroksen neuroverkoille luotu oppimistekniikka, joka otettiin käyttöön neuroverkkojen tehokkuuden ja nopeuden parantamiseksi (Sharma & Deo 2021). ELM:n uskotaan oppivan tuhansia kertoja nopeammin kuin takaisinsyöttötekniikalla koulutetut neuroverkot (Lendave 2021). Tutkijat saattavat suosivat ELM menetelmää perinteisten neuroverkkojen sijaan niiden oppimisnopeuden ansiosta. (Sharma & Deo 2021) ELM:t eivät nopeasta oppimisestaan tai tehokkuudestaan huolimatta tuota yhtä tarkkoja tuloksia kuin perinteiset neuroverkot (Erdem 2020).

Harjoitusvaiheen jälkeen ennustus menetelmälle syötetään testi dataa, jolle valitaan harjoitusvaiheessa luoduista ennustemenetelmistä sopivin, hyödyntämällä ensemble oppimismenetelmää, joka testaa viiden erilaisen linkitysmenetelmän avulla, että mikä ennustemenetelmä on datalle sopivin. (Lu & Kao 2016)

Ensemble-oppiminen on menetelmä, jossa luodaan kuvan 8 tavoin valittu määrä ennustus osajoukkoja, joiden ennusteet yhdistetään yksittäisen päätöksen tai ennustemenetelmän luomiseksi. Ensemble oppimismenetelmää käytetään yleisimmin ennustus- ja luokittelu algoritmien suorituskyvyn kasvattamisessa. (Lu & Kao 2016)



**Kuva 8:** Ensemble oppimisprosessi (Muunneltu lähteestä Lu & Kao 2016)

Tutkimuksesta voidaan huomata, että ehdotettu myynnin ennustamisjärjestelmä tuotti parhaat ennustetulokset. Ryhmittelyyn perustuva menetelmä suoriutui tilastollisesti parempi kuin mallit, joissa ei ryhmitely dataa. Tutkimuksen tuloksesta voidaan todeta, että yhdistelemällä erilaisia koneoppimisen algoritmeja voidaan parantaa yksittäisen ennustemallin suorituskykyä.

## 4.2 Varastohallinta

Varastohallintaan liittyvät kustannukset synnyttävät toimitusketjuille huomioonotettavia kustannuksia, jonka takia niitä yritetään jatkuvasti vähentää suunnittelemalla varastojen materiaalivirtoja paremmin. Varastohallinta yksiköiden yksi suurimmista ongelmista on tietämättömyys ja epävarmuus päätöksenteossa. (Tirkolae, Sadedghi, Mooseloo, Vandchali & Aeini 2021)

Gumuksen, Gunerin & Ulengin (2010) suorittaman tutkimuksen tarkoituksena oli taata perinteisiä varastohallinta malleja tehokkaammat kustannus- ja varastolaskelmat sekä toimitusketjujen järjestelyt. Gumus et al. (2010) tutkimuksessa



simuloidaan kolmivaiheista elintarvikeketjua, joka koostuu kolmesta jälleenmyyjästä, kahdesta jakelijasta ja yhdestä varastosta. Tutkimuksessa hyödynnetään neuro-sumea menetelmää epäluotettavien muuttujien ennustamisessa. (Gumus et al. 2010) Neuro-sumea menetelmä on nimeltään ANFIS ja sitä käytetään tilausten kysynnän, sekä läpimenoaikojen ennustamiseen ja tutkimuksen mukaan se tuottaa perinteisiä varastohallintajärjestelmiä realistisempia tuloksia (Gumus et al. 2010)

ANFIS järjestelmä käyttää neuroverkon oppimisalgoritmeja ja sumea logiikka menetelmän päättelyä (Gumus et al. 2010). Käyttämällä hybridioppimismenetelmää ehdotettu ANFIS voi rakentaa syötteen ja tuloksen välisen kartoituksen, joka perustuu ihmisen tietoon, että määrättyihin syötteen ja tuloksen datapareihin. ANFIS arkkitehtuuria käytetään epälineaaristen funktioiden mallintamiseen sekä tunnistamiseen, joissa se on Gumus et al. mukaan tuottanut huomionarvoisia tuloksia.

Tutkimuksessa ennustusmenetelmää koulutettiin 1000 syklin ajan käyttämällä 108 datasettiä. Koulutuksen tarkoituksena oli opettaa menetelmä ennustamaan seuraavan 12 kuukauden minimikustannukset hyödyntämällä kysyntä- ja läpimenoaika ennusteita (Gumus et al. 2010). Tutkimuksessa ennustemenetelmän tuloksia tutkitaan perehtymällä sen ennustetarkkuuteen, reagointikykyyn, joustavuuteen ja kustannuksien muutokseen. Tutkimuksen tuloksena ANFIS menetelmä on nostanut toimitusketjun suorituskykyä laskemalla varaston läpimenoaikoja. Tutkimuksessa yksittäisen paketin tilauksen läpimenoaika on noin 58% lyhyempi, kuin aikaisemmin. Läpimenoaikojen muutos on vaikuttanut myös varastointikustannuksiin, vähentämällä niiden määrää huomattavasti. (Gumus et al. 2010) Tutkimuksen perusteella on syytä uskoa, että varastot kykenevät tekemään merkittäviä säästöjä ja tehostamaan toimintaansa hyödyntämällä koneoppimismenetelmiä materiaalivirtojen suunnittelussa.

### **4.3 Jakelu**

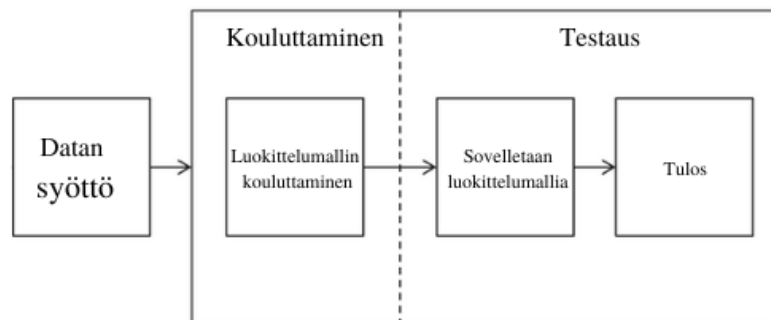
Yksi suosituimmista koneoppimisen sovelluksista on toimitusketjujen hallinnointi, johon kuuluu ajoneuvojen reititys- ja jakeluongelmien ratkaiseminen. Jakelun hallinnoimisen kolme keskeisintä tavoitetta ovat lyhyet läpimenoajat, korkea aikataulujen

luotettavuus ja alhaiset kustannukset. Mainitut tavoitteet edistävät asiakkaiden vaatimusten täyttämistä, suunnitteluvarmuutta ja taloudellista hyvinvointia. (Becker et al. 2016)

Kuljetusajoneuvon kulkemien optimaalisten reittien valinta on tärkeää, jotta toimitusketju voi toimittaa tuotteen asiakkaalle mahdollisimman nopeasti ja vähäisin kustannuksin (Becker et al. 2016). Jakelureittien suunnitteleminen ylittää useimmissa tapauksissa ihmisaivojen kyvyt suurien data määrien takia, jolloin on optimaalista käyttää koneoppimisen menetelmiä hyväksi. Huonosti hallittu kokonaisuus aiheuttaa tehottomia reitityspäätöksiä, jotka puolestaan aiheuttavat viivästyksiä jakeluissa (Becker et al. 2016). Koneoppimisen menetelmät tunnetusti toimivat erinomaisesti suurien ja monipuolisten tietokokonaisuuksien analysoimisessa ja ne tuottavat nopeasti tarkkoja tuloksia (Ni et al. 2020).

Becker et al. (2016) tutkimuksessa osoitettiin, että neuroverkkoja hyödyntämällä voidaan hallita logistiikkalaitoksen reitityspäätöksiä paremmin kuin perinteisimmillä menetelmillä. Tutkimuksessa keskitytään 46 500 ajoneuvon, historialliseen dataan, joiden reitityspäätökset on luotu uudestaan neuroverkko teknologiaa käyttämällä. Neuroverkko määrittää jokaiselle ajoneuville nopeimman läpimenoajan tarjoavan reititysreitit. Tutkimuksesta käy ilmi, että neuroverkkomenetelmä parantaa ajoneuvojen läpimenoaikoja noin 12,7%, joka on noin 48% parannus suorituskyvyssä, parhaiten suoriutuvaan heuristiseen menetelmään verrattuna. Läpimenoaikojen parannus merkitsee tämän tutkimuksen tilanteessa myös tulojen kasvua, koska terminaali ehtii palvelemaan suuremman määrän asiakkaita kuin aikaisemmin. Voidaan sanoa tutkimuksen perusteella, että koneoppimisen hyödyntäminen jakelussa auttaa toimitusketjua pääsemään tavoitteisiinsa koskien läpimenoaikoja ja kustannuksien alentamista. Becker et al. (2016) tutkimuksessa käy myös ilmi, että neuroverkkomallin päätöksentekovapautta lisättäessä ajoneuvojen läpimenoajat paranivat noin 14%. Tuloksesta voidaan huomata, että neuroverkkomallin suorituskyky on tehokkaimmillaan silloin, kun sen päätöksentekoa rajoitetaan mahdollisimman vähän.

Keller et al. (2014) tutkimus keskittyy (RFID) teknologian tämänhetkisten ongelmien ratkaisemiseen hyödyntämällä koneoppimismenetelmiä. RFID teknologian käyttö tuo toimitusketjuille niiden tarvitsemaa näkyvyyttä ja jäljitettävyyttä, mutta sen tuoma teho heikkenee esimerkiksi varastoissa, joissa RFID-lukija saattaa lukea minkä tahansa lukualueelle ilmestyneen tunnisteeseen (Keller et al. 2014). Vääräpositiiviset lukemat lisäävät jakelu ja varastotaso-ongelmia, koska RFID tietokannassa saattaa lukea tavaran lähteneen varastolta asiakkaalle, vaikka tavara olisikin vielä varastossa. Tutkimuksessa perehdytään muun muassa päätöspuiden hyödyntämiseen RFID datan luokittelumalleina. Luokittelumalli seuraa yleistä koulutus- ja testausmenettelyä, jossa se käsittelee sille luotua harjoitusdataa. Kuvasta 9 nähdään koulutusrakenteen lisäksi, että harjoitus data pidetään erillään testi datasta. (Keller et al. 2014)



**Kuva 9: Koneoppimismenetelmän koulutus- ja testausprosessi** (Muunneltu lähteestä Keller et al. 2014)

Keller et al. (2014) tutkimuksen mukaan hyvän luokittelumallin luominen edellyttää otosdatajoukkoa, jonka luokkatunnisteet ovat tiedossa. Tutkimuksen data koostuu 30 viikon ajan siirrettyjen ja paikallaan olevien kuormalavojen RFID tunnisteiden signaaleista. Monitoroituja kuormalavoja on yhteensä noin 93000, joista kertyi yhteensä noin 2,6 miljoonaa tunniste havaintoa. (Keller et al. 2014)

Päätöspuut pystyvät erottelmaan vääräpositiivisia tapauksia niiden yksinkertaisten yksiulotteisten raja-arvojen perusteella. Harjoitus- ja testivaiheessa syntyvien puurakenteiden avulla voi jäljittää ja hahmottaa miten luokittelumalli on tehnyt päätöksensä. Päätöspuiden vääräpositiivisten lukemien luokittelutarkkuus oli lähes

poikkeuksetta 95%, kun hyödynnettiin RFID lukulaitteiston tuottaman tiedon koko tietopakettia eikä vain tiettyjä attribuutteja. (Keller et al. 2014)

## 5 Johtopäätökset

Opinnäytetyön tavoitteena oli tutkia, miten koneoppimista voidaan hyödyntää materiaalivirtojen suunnittelemisessa. Lisäksi työssä selvitettiin millaisia hyötyjä ja mitä haasteita koneoppimisen hyödyntäminen voi tuoda toimitusketjuille. Tutkimuksessa vastataan kolmeen tutkimuskysymykseen seuraavasti:

*Millaisia koneoppimismenetelmiä käytetään toimitusketjujen materiaalivirtojen suunnittelussa?*

Ensimmäiseen kysymykseen vastataan tutkielman kolmannessa luvussa. Luvussa selviää, että toimitusketjut hyödyntävät yleisimmin vain noin kymmentä koneoppimisen menetelmää materiaalivirtojen suunnittelussa. Näistä esiteltiin tutkielman kannalta tärkeimmät menetelmät, joita olivat neuroverkot, K-means klusterointi ja päätöspuut. Seuraava kysymys on:

*Mitä haasteita koneoppimisen hyödyntämiseen liittyy?*

Koneoppimisen hyödyntämiseen liittyy haasteita. Näitä haasteita ovat muun suuren tietomäärän saatavuus, datan heikko laatu, Oikean menetelmän valitseminen, koneoppimismenetelmän yli- ja alisovittaminen. Koneoppimisalgoritmit tarvitsevat suuren määrän dataa toimiakseen tehokkaasti, jota kaikilla yrityksillä ei ole. Suuren data määrän lisäksi tulee datan putsamiseen ja laadun tarkastamiseen käyttää paljon aikaa, muuten koneoppimismenetelmä saattaa tehdä virheellisiä päätelmiä. Vaikka koneoppiminen olisikin yritykselle todella hyödyllinen työkalu, niin ei sen implementointi ole kuitenkaan aina helppoa. Mainitut koneoppimisen menetelmät ja niiden haasteet tukevat seuraavaa kysymystä. Seuraava kysymys on tutkielman pääkysymys:

*Miten koneoppimista voidaan hyödyntää toimitusketjuissa, erityisesti kysynnän suunnittelussa, varastonhallinnassa ja jakelussa?*

Pääkysymykseen vastataan tutkielman neljännessä luvussa. Työssä käsitellään, millaisia menetelmiä käytetään tänä päivänä toimitusketjujen kysynnän, varastonhallinnan ja jakelun materiaalivirtojen suunnitteluun. Toimitusketjujen kulujen ja toiminnan optimoiminen on yrityksille tärkeää hyvän kilpailuaseman saavuttamiseksi, jonka takia koneoppimisen algoritmeille etsitään jatkuvasti uusia käyttötarkeitä.

Tutkimuksessa koneoppimisen hyödyntäminen kysynnän ennustamisessa vähensi toimintakustannuksia merkittävästi perinteisiin menetelmiin verrattuna ja paransi yrityksen päätöksentekoa tehokkuutta. Optimoimalla kysynnän ennustamisen yritykset eivät kuluta ylimääräistä rahaa turhien täydennystoimituksien varastointiin. Huomattiin myös, että yhdistelemällä koneoppimismenetelmiä, saadaan parempia tuloksia.

Varastonhallinnan suurin ongelma on siihen liittyvien kulujen suuruus, joita ei olla aikaisempia menetelmiä hyödyntämällä saatu laskettua. Neuroverkkomenetelmään perustuvaa teknologiaa hyödyntämällä saatiin lyhennettyä varaston läpimenoaika ja laskettua varaston kiinteitä kustannuksia suunnattomasti aiempiin kustannuksiin verrattuna.

Jakeluverkoista on toimittajien- ja asiakkaiden määrän kasvun myötä tullut todella hankalaa. Neuroverkkoja hyödyntämällä jakeluverkkojen suorituskyky oli paljon parempi kuin mihin perinteiset logistiikkalaitokset ovat kyenneet. Luvussa huomattiin myös, että mitä enemmän päätöksentekoa valtaa annettiin neuroverkolle, niin sitä paremmaksi prosentuaalinen suorituskyky logistiikkakeskuksessa nousi.

Kokonaisuudessa tutkimus osoittaa, että nykyaikaiset toimitusketjujen menetelmät voivat hyötyä paljon koneoppimisen tarjoamista hyödyistä. Tulee kuitenkin huomioida, että tutkielmat eivät aina suoriudu käytännössä yhtä hyvin kuin paperilla. Aiheesta tulisi tehdä jatkotutkimuksia siitä, että kuinka hyvin mainitut menetelmät suoriutuvat, kun ne laitetaan oikeasti käytäntöön.

## Lähteet

Akabane, G., Tarallo, E. & Shimabukuro, C. 2019. Machine Learning in Predicting Demand for Fast-Moving Consumer Goods: An Exploratory Research [verkkodokumentti]. [Viitattu 23.03.2022]. Saatavilla: [https://www.researchgate.net/profile/Elcio-Tarallo-2/publication/338172563\\_Machine\\_Learning\\_in\\_Predicting\\_Demand\\_for\\_Fast-Moving\\_Consumer\\_Goods\\_An\\_Exploratory\\_Research/links/5fa18166458515b7cfb5f0c5/Machine-Learning-in-Predicting-Demand-for-Fast-Moving-Consumer-Goods-An-Exploratory-Research.pdf](https://www.researchgate.net/profile/Elcio-Tarallo-2/publication/338172563_Machine_Learning_in_Predicting_Demand_for_Fast-Moving_Consumer_Goods_An_Exploratory_Research/links/5fa18166458515b7cfb5f0c5/Machine-Learning-in-Predicting-Demand-for-Fast-Moving-Consumer-Goods-An-Exploratory-Research.pdf)

Akerkar, R. 2019. Artificial Intelligence for Business.

Ashayeri, J. & Lemmes, L. 2006. Economic value added of supply chain demand planning: A system dynamics simulation. [Viitattu: 03.04.2022] Saatavilla: <https://www.sciencedirect.com/science/article/abs/pii/S073658450600069X#!>

Badillo, S., Banfai, B & Birzele, F. 2020. An Introduction to Machine Learning [verkkodokumentti]. [Viitattu 03.03.2022]. Saatavilla: <https://ascpt.onlinelibrary.wiley.com/doi/pdfdirect/10.1002/cpt.1796>

Bartholdi J & Hackman S. 2011. Warehouse and distribution science. [Viitattu: 29.02.2022] Saatavilla:

Becker, T., Illigen, C., McKelvey B., Hülsmann, M. & Windt, K. 2016. Using an agent-based neural-network computational model to improve product routing in a logistics facility [WWW-dokumentti]. [Viitattu 25.04.2022]. Saatavilla: <https://www-sciencedirect-com.ezproxy.cc.lut.fi/science/article/pii/S0925527316000049>

Brown, S. 2021. Machine learning, explained. [verkkodokumentti]. [Viitattu 23.03.2022]. Saatavilla: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>

Brownlee, J. 2017. Master Machine Learning Algorithms

Carbonneau, R., Laframboise, K. & Vahidov, R. 2018. Application of machine learning techniques for supply chain demand forecasting [verkkodokumentti]. [Viitattu 16.03.2022]. Saatavilla: <https://www.sciencedirect.com/science/article/abs/pii/S0377221706012057>

Carbonneau, R., Vahidov, R. & Laframboise, K. 2007. Machine learning-Based Demand forecasting in supply chains [verkkodokumentti]. [Viitattu 25.03.2022]. Saatavilla: [https://www.researchgate.net/profile/Real-Carbonneau/publication/220208887\\_Machine\\_Learning-Based\\_Demand\\_Forecasting\\_in\\_Supply\\_Chains/links/57c4463a08ae32a03dad3de9/Machine-Learning-Based-Demand-Forecasting-in-Supply-Chains.pdf](https://www.researchgate.net/profile/Real-Carbonneau/publication/220208887_Machine_Learning-Based_Demand_Forecasting_in_Supply_Chains/links/57c4463a08ae32a03dad3de9/Machine-Learning-Based-Demand-Forecasting-in-Supply-Chains.pdf)

Chauhan, N. 2022. Decision Tree Algorithm, Explained [verkkodokumentti]. [Viitattu 12.04.2022]. Saatavilla: <https://www.kdnuggets.com/2020/01/decision-tree-algorithm-explained.html>

Cheng, J., Chen, H. & Lin, Y. 2010. A hybrid forecast marketing timing model based on probabilistic neural network, rough set and C4.5 [verkkodokumentti]. [Viitattu 25.03.2022]. Saatavilla: LINK

Choi, R., Coyner, A., Kalpathy-Cramer, J. & Chiang, M. 2020. Introduction to Machine Learning, Neural Networks, and Deep Learning [verkkodokumentti]. [Viitattu 28.03.2022]. Saatavilla: <https://tvst.arvojournals.org/article.aspx?articleid=2762344>



Erdem, K. 2020. Introduction to Extreme Learning Machines [verkkodokumentti]. [Viitattu 21.04.2022]. Saatavilla: <https://towardsdatascience.com/introduction-to-extreme-learning-machines-c020020ff82b>

Faria, B., Reis, L., Lau N. & Castillo G. 2010. Machine Learning Algorithms applied to the Classification of Robotic Soccer Formations and Opponent Teams [verkkodokumentti]. [Viitattu 14.03.2022]. Saatavilla: <http://sweet.ua.pt/gladys/Papers/MonicaSingapur2010.pdf>

Flach, P. 2012. Machine Learning: The Art and Science of Algorithms that Make Sense of Data.

Frazelle, E. 2002. SUPPLY CHAIN STRATEGY The Logistics of Supply Chain Management [Viitattu: 11.03.2022]

Gayialis, P. & Tatsiopoulos, P. 2004. 4: Design of an IT-driven decision support system for vehicle routing and scheduling. *European Journal of Operational Research*, 152. (382–398) [Viitattu 25.04.2022].

Gong, Y. 2008. A polling-based dynamic order picking system for online retailers. *IIE Transactions* 40 pages:1070–1082. [Viitattu: 12.03.2022] Saatavilla:

Grant, David B., Lambert, D., James, R. Stock, and Lisa, Ellram. 2006. *Fundamentals of Logistics Management: European edition*. Berkshire: McGraw-Hill Education.

Gu, J., Goetschalckx, M. & McGinnis, L. 2007. Research on warehouse operation: A comprehensive review: *European Journal of Operational Research* 177 1-21

Gumus, A., Guneri, A. & Ulengin, F. 2010. A new methodology for multi-echelon inventory management in stochastic and neuro-fuzzy environments [verkkodokumentti]. [Viitattu 12.04.2022]. Saatavilla: [http://scinet.science.ph/union/Downloads/science\\_024\\_313965.pdf](http://scinet.science.ph/union/Downloads/science_024_313965.pdf)

Gunjan, V., Diaz, V., Cardona, M. & Solanki, V. 2019. ICICCT 2019 – System Reliability, Quality Control, Safety, Maintenance and Management [verkkodokumentti]. [Viitattu 10.02.2022]. Saatavilla: <https://link-springer-com.ezproxy.cc.lut.fi/content/pdf/10.1007%2F978-981-13-8461-5.pdf>

Géron, A. 2019. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow 24–30

Hardesty, L. 2017. Explained: Neural networks [verkkodokumentti]. [Viitattu 25.04.2022]. Saatavilla: <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>

Heung, H. & Cho, G. 2006. A performance evaluation model for order picking warehouse design, *Computers & Industrial Engineering* Vol. 51(2), pages: 335-342. [Viitattu: 14.04.2022]

Hosseini, S. & Khaled, A. 2019. A hybrid ensemble and AHP approach for resilient supplier selection [verkkodokumentti]. [Viitattu -]. Saatavilla: <https://www.proquest.com/docview/2170243651?OpenUrlRefId=info:xri/sid:primo&accountid=27292&parentSessionId=Q08oFjKDKzXWJ0Ee6Th0LEalHQC0vTsot-FfYN2v2DHs%3D>

Hsu H., Chang, C., & Hsu, C., 2017. Big Data Analytics for Sensor-Network Collected Intelligence [verkkodokumentti]. [Viitattu 21.04.2022]. Saatavilla: <https://www.sciencedirect.com/book/9780128093931/big-data-analytics-for-sensor-network-collected-intelligence>

IBM. 2021. The Neural Networks Model [verkkodokumentti]. [Viitattu 25.04.2022]. Saatavilla: <https://www.ibm.com/docs/en/spss-modeler/18.0.0?topic=networks-neural-model>

Interlake Mecalux. 2019. What is a lead time in logistics? And how to optimize it. [verkkodokumentti]. [Viitattu 26.04.2022]. Saatavilla: <https://www.interlakemecalux.com/blog/logistics-lead-time>

James, G., Witten, D., Hastie, T. & Tibshirani, R. 2013. An Introduction to Statistical Learning. [Viitattu 16.04.2022].

Jane, B. & Ganesh, N. 2019. A Review On Big Data With Machine Learning And Fuzzy Logic For Better Decision Making [verkkodokumentti]. [Viitattu 12.04.2022] Saatavilla: <http://www.ijstr.org/final-print/oct2019/A-Review-On-Big-Data-With-Machine-Learning-And-Fuzzy-Logic-For-Better-Decision-Making.pdf>

Jiang, T., Gradus, J. & Rosellini, A. 2020. Supervised Machine Learning: A Brief Primer

Joshi, A. 2020. Machine Learning and Artificial Intelligence, Springer International Publishing.

Keboola. 2020. The Ultimate Guide to Decision Trees for Machine Learning [verkkodokumentti]. [Viitattu 21.04.2022]. Saatavilla: <https://www.keboola.com/blog/decision-trees-machine-learning>

Keller, Y., Thiesse, F. & Fleisch, E. 2014. Classification Models for RFID-Based Real-Time Detection of Process Events in the Supply Chain: An Empirical Study [verkkodokumentti]. [Viitattu 23.03.2022]. Saatavilla: <https://dl-acm-org.ezproxy.cc.lut.fi/doi/pdf/10.1145/2629449>

Knolmayer, G., Mertens, P. & Zeier, A. 2002. Supply chain management based on SAP systems: order management in Manufacturing Companies. Springer [verkkodokumentti]. [Viitattu 25.04.2022]. S 103

Košiček, M., Dařena, F., Malo, R., Motycka, A. & Tesař, R. 2012. Route planning module as a part of Supply Chain Management system [verkkodokumentti]. [Viitattu 25.04.2022]. Saatavilla: [https://www.researchgate.net/publication/273207454\\_Route\\_planning\\_module\\_as\\_a\\_part\\_of\\_Supply\\_Chain\\_Management\\_system](https://www.researchgate.net/publication/273207454_Route_planning_module_as_a_part_of_Supply_Chain_Management_system)

Lakshmi, D. 2020. Explained: Vehicle Routing Problem (VRP) and the most effective solution to address it. [WWW-dokumentti]. [Viitattu 25.04.2022]. Saatavilla: <https://blog.locus.sh/vehicle-routing-problem-decoded-what-why-and-how/>

Lee, H. 2001. Ultimate enterprise value creation using demand-based management. Stanford Global Supply Chain, Management Forum September 2001. [Viitattu: 05.04.2022] Saatavilla: <https://www.gsb.stanford.edu/faculty-research/publications/ultimate-enterprise-value-creation-using-demand-based-management>

Lendave, V. 2021. A Beginner's Guide to Extreme Learning Machine [verkkodokumentti]. [Viitattu 21.04.2022]. Saatavilla: <https://analyticsindiamag.com/a-beginners-guide-to-extreme-learning-machine/>

Louridas, P. & Ebert, C. 2016. Machine Learning [verkkodokumentti]. [Viitattu 23.03.2022]. Saatavilla: <https://ieeexplore-ieee.org.ezproxy.cc.lut.fi/stamp/stamp.jsp?tp=&arnumber=7548905>

Lu, C. & Kao, L. 2016. A clustering-based sales forecasting scheme by using extreme learning machine and ensembling linkage methods with applications to computer server [verkkodokumentti]. [Viitattu 24.02.2022]. Saatavilla: <https://www.sciencedirect.com/science/article/abs/pii/S0952197616301257>

McKinsey. 2017. ARTIFICIAL INTELLIGENCE THE NEXT DIGITAL FRONTIER? [verkkodokumentti]. [Viitattu 15.02.2022]. Saatavilla: <https://www.mckinsey.com/~media/McKinsey/Industries/Advanced%20Electronics/Our%20Insights/How%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/MGI-Artificial-Intelligence-Discussion-paper.ashx>

Ni, D., Xiao, Z. & Lim, M. 2020. A systematic review of the research trends of machine learning in supply chain management [verkkodokumentti]. [Viitattu 20.03.2022]. Saatavilla: [https://www.researchgate.net/publication/338101452\\_A\\_systematic\\_review\\_of\\_the\\_research\\_trends\\_of\\_machine\\_learning\\_in\\_supply\\_chain\\_management](https://www.researchgate.net/publication/338101452_A_systematic_review_of_the_research_trends_of_machine_learning_in_supply_chain_management)

Ning, A., Lau, H., Zhao, Y. & Wong, T. 2009. Fulfillment of Retailer Demand by Using the MDL-Optimal Neural Network Prediction and Decision Policy [verkkodokumentti]. [Viitattu 04.04.2022]. Saatavilla: <https://ieeexplore-ieee.org.ezproxy.cc.lut.fi/stamp/stamp.jsp?tp=&arnumber=5256154&tag=1>

Norvig, P. & Russell, S. 2009. *Artificial Intelligence: A Modern Approach*. Upper Saddle River, Prentice Hall. 1152 s. 695–697

Oliveria, F. & Rana, R. 2014. Real-time dynamic pricing in a non-stationary environment using model-free reinforcement learning [verkkodokumentti]. [Viitattu 13.03.2022]. Saatavilla: <https://www.sciencedirect.com/science/article/abs/pii/S030504831300100X>

Panesar, A. 2021. Machine Learning and AI for Healthcare [verkkodokumentti]. [Viitattu 26.04.2022]. S 69-90

Ponte, B., Costas, J., Puche, J., Pino, R. and Fuente, D. 2018. The value of lead time reduction and stabilization: A comparison between traditional and collaborative supply chains. *Transportation Research Part E: Logistics and Transportation Review*, 111, s.165-185.

Pulkit, S. 2019. The Most Comprehensive Guide to K-Means Clustering You'll Ever Need [verkkodokumentti]. [Viitattu 24.04.2022]. Saatavilla: <https://www.analyticsvidhya.com/blog/2019/08/comprehensive-guide-k-means-clustering/>

PurolatorInternational. 2020. How to Cut Costs in Your Supply Chain with Effective Routing [verkkodokumentti]. [Viitattu 25.04.2022]. Saatavilla: <https://www.purolatorinternational.com/how-to-cut-costs-in-your-supply-chain-with-effective-routing/>

Ramaa, A., Subramanya, K. & Rangaswamy, T. 2012. Impact of Warehouse Management System in a Supply Chain. [Viitattu: 20.04.2022] Saatavilla: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.258.6734&rep=rep1&type=pdf>

Rana, R. & Oliveira, F A. 2018. Dynamic pricing policies for interdependent perishable products or services using reinforcement learning [verkkodokumentti]. [Viitattu 14.04.2022]. Saatavilla: <https://www.sciencedirect.com/science/article/abs/pii/S095741741400400X>

Rebala, G., Ravi, A. and Churiwala, 2019 *An Introduction to Machine Learning*, Springer International Publishing.

Gwynne R. 2011. *Warehouse Management: A complete guide to improving efficiency and minimizing costs in the modern warehouse*. London: Kogan Page Limited.

Sharma, N. & Deo, R. 2021. Wind speed forecasting in Nepal using self-organizing map-based online sequential extreme learning machine [verkkodokumentti]. [Viitattu 21.04.2022]. Saatavilla: <https://www.sciencedirect.com/science/article/pii/B9780128177723000148>

Singh, A., Shukla, N. & Mishra, N. 2018. Social media data analytics to improve supply chain management in food industries [verkkodokumentti]. [Viitattu 16.03.2022]. Saatavilla: <https://www-sciencedirect-com.ezproxy.cc.lut.fi/science/article/pii/S1366554516303817>

Stadtler, H., Kilger, C. & Meyer, H. 2008. *Supply Chain Management and Advanced Planning: A system dynamics simulation*. [Viitattu: 13.03.2022] Saatavilla: <https://link.springer.com/book/10.1007/978-3-642-55309-7?noAccess=true>

Thomassey, S. & Fiordaliso, A. 2006. A hybrid sales forecasting system based on clustering and decision trees [verkkodokumentti]. [Viitattu 23.04.2022]. Saatavilla: <https://www.sciencedirect.com/science/article/abs/pii/S016792360500ning0114>

Thomassey, S. 2010. Sales forecasts in clothing industry: The key success factor of the supply chain management [verkkodokumentti]. [Viitattu 25.04.2022]. Saatavilla: <https://www.sciencedirect.com/science/article/abs/pii/S0925527310002598>

Timme, S. 2003. The real cost of holding inventory,” Supply Chain Management Review [verkkodokumentti]. [Viitattu 23.02.2022]. Saatavilla: <https://www-proquest-com.ezproxy.cc.lut.fi/docview/221232080?pq-origsite=primo>

Tirkolae, E., Sadeghi, S., Mooseloo, F., Vandchali, H. & Aeini, S. 2021. Application of Machine Learning in Supply Chain Management: A Comprehensive Overview of the Main Areas [verkkodokumentti]. [Viitattu 23.02.2022]. Saatavilla: <https://www.hindawi.com/journals/mpe/2021/1476043/>

Zhou, J. & Chen, F. 2018. Human and Machine Learning