



**DATA-ANALYTIIKAN HYÖDYNTÄMINEN KYSYNNÄN ENNUSTAMISESSA  
VAATETEOLLISUUDESSA**

Utilizing data analytics in demand forecasting in the clothing industry

Lappeenrannan–Lahden teknillinen yliopisto LUT

Tuotantotalouden kandidaatintyö

2023

Alisa Pohjasmäki

Tarkastaja: Tutkijatohtori Lasse Metso

## TIIVISTELMÄ

Lappeenrannan–Lahden teknillinen yliopisto LUT

LUT Teknis-luonnontieteellinen

Tuotantotalous

Alisa Pohjasmäki

### **Data-analytiikan hyödyntäminen kysynnän ennustamisessa vaateteollisuudessa**

Tuotantotalouden kandidaatintyö

2023

30 sivua, 3 kuvaa ja 1 taulukko

Tarkastaja: Tutkijatohtori Lasse Metso

Avainsanat: Data-analytiikka, vaateteollisuus, kysynnän ennustaminen

Työn tavoitteena on selvittää, miten data-analytiikkaa voidaan hyödyntää kysynnän ennustamisessa vaateteollisuudessa. Tutkimuksen alussa perehdytään data-analytiikkaan ja siihen liittyviin käsitteisiin. Tämän jälkeen käsitellään vaateteollisuuden ominaispiirteitä ja toimitusketjuja sekä avataan kysynnän ennustamiseen liittyvää teoriaa. Lopuksi käydään läpi datan lähteitä sekä data-analytiikan hyödyntämismahdollisuuksia kysynnän ennustamisessa vaateteollisuudessa. Työ on toteutettu kirjallisuuskatsauksena.

Kysynnän ennustaminen vaateteollisuudessa on lähtökohtaisesti haastavaa, mikä johtuu historiadatan puutteesta, nopeasti vaihtuvista muotitrendeistä sekä kysynnän epävakauudesta. Ennustamisen haasteellisuus vaikeuttaa kysynnän ja tarjonnan yhteensovittamista, mikä aiheuttaa erilaisia ongelmia yrityksille. Kysynnän ennustamisessa käytettävien menetelmien kehittäminen on tämän takia tärkeää.

Tutkimuksen tulosten perusteella data-analytiikan menetelmiä on mahdollista hyödyntää kysynnän ennustamisessa vaateteollisuudessa. Vaateteollisuuden yritykset voivat kerätä dataa sisäisistä sekä ulkoisista datalähteistä. Merkittävänä haasteena on uusien tuotteiden kysynnän ennustaminen. Uusien tuotteiden kysyntää voidaan ennustaa hyödyntämällä aikaisemmin myynnissä olleiden samankaltaisten tuotteiden historiadataa. Lisäksi data-analytiikan avulla voidaan analysoida sosiaalisesta mediasta saatavaa dataa, jota voidaan hyödyntää kuluttajien mieltymysten analysoimisessa ja muotitrendien tunnistamisessa.

## Sisällysluettelo

1	Johdanto .....	3
1.1	Työn tavoite, rajaus ja toteutus.....	3
1.2	Työn rakenne .....	4
2	Data-analytiikka .....	6
2.1	Datan määritelmä.....	6
2.2	Big data.....	7
2.3	Data-analytiikka .....	8
3	Vaateteollisuus ja kysynnän ennustaminen.....	11
3.1	Vaateteollisuuden ominaispiirteet .....	11
3.2	Toimitusketjut vaateteollisuudessa.....	12
3.3	Kysynnän ennustaminen.....	16
4	Kysynnän ennustaminen data-analytiikan avulla vaateteollisuudessa.....	18
4.1	Datan lähteet vaateteollisuudessa .....	18
4.2	Data-analytiikka kysynnän ennustamisessa vaateteollisuudessa.....	19
5	Johtopäätökset .....	22
	Lähteet .....	25

# 1 Johdanto

Digitalisaatio ja teknologian kehitys ovat mahdollistaneet datan määrän suuren kasvun (Gandomi & Haider, 2015). Teknologian kehityksen myötä myös datan analysoimisessa käytettävät data-analytiikan menetelmät ovat kehittyneet. Data-analytiikan avulla eri lähteistä saatavaa dataa on mahdollista hyödyntää päätöksenteossa ja liiketoiminnassa. (Davenport, 2013) Tärkeä data-analytiikan hyödyntämiskohde on kysynnän ennustaminen (Souza, 2014).

Vaateteollisuudessa kysynnän ennustaminen on haastavaa, minkä takia erilaisia menetelmiä ja tekniikoita on jo pitkään pyritty kehittämään ennustamisen tueksi. Kysynnän ennustamisessa käytettävien menetelmien kehittäminen on tärkeää, sillä ennustamisen haasteellisuus vaikeuttaa yritysten toimintojen suunnittelua ja hankaloittaa kysynnän ja tarjonnan yhteensovittamista. (Nenni, Giustiniano & Pirolo, 2013) Teknologian kehityksen sekä saatavilla olevan datan suuren määrän takia on aiheellista selvittää, miten data-analytiikkaa voidaan hyödyntää kysynnän ennustamisessa vaateteollisuudessa.

## 1.1 Työn tavoite, rajaus ja toteutus

Tutkimuksen tavoitteena on selvittää, miten vaateteollisuuden yritykset voivat hyödyntää data-analytiikkaa kysynnän ennustamisessa. Kattavan kokonaiskuvan saamiseksi tutkimuksessa perehdytään siihen, mitkä tekijät vaikuttavat vaateteollisuuden kysyntään sekä siihen vastaamiseen. Tämän selvittämiseksi työssä perehdytään vaateteollisuuden ominaispiirteisiin sekä toimitusketjuihin. Data-analytiikan hyödyntämisessä oleellista on analysoitava data ja sen lähteet. Tämän takia tutkimuksessa selvitetään, mistä lähteistä vaateteollisuudessa hyödynnettävää dataa voidaan kerätä. Työssä perehdytään lisäksi data-analytiikkaan liittyviin käsitteisiin sekä kysynnän ennustamiseen liittyvään teoriaan. Työn päätutkimuskysymys on:

- *Miten data-analytiikkaa voidaan hyödyntää kysynnän ennustamisessa vaateteollisuudessa?*

Päätutkimuskysymyksen tukena käytetään seuraavia osakysymyksiä:

- *Mitkä ovat vaateteollisuuden ominaispiirteet?*
- *Mistä lähteistä vaateteollisuudessa hyödynnettävää dataa voidaan kerätä?*

Työ toteutetaan kirjallisuuskatsauksena. Päälähteinä käytetään datan analysoimiseen ja hyödyntämiseen sekä vaateteollisuuden ja kysynnän ennustamiseen liittyvää tieteellistä kirjallisuutta ja tutkimusaineistoa. Työn rajaus perustuu toimialakohtaiseen rajaukseen, eli työssä käsitellään data-analytiikan hyödyntämistä kysynnän ennustamisessa nimenomaan vaateteollisuudessa.

## 1.2 Työn rakenne

Työ pitää sisällään viisi päälukua, joista ensimmäisenä on työn aiheeseen ja taustaan lukijan perehdyttävä johdanto. Kirjallisuuteen perehtymisen avulla työssä selvitetään johdannon jälkeen data-analytiikkaan liittyviä tärkeitä käsitteitä. Tavoitteena on antaa selkeä kuva siitä, mitä tarkoitetaan datalla, big datalla ja data-analytiikalla. Tämän jälkeen käsitellään vaateteollisuutta ja selvitetään, mitä ominaispiirteitä vaateteollisuudella on, ja millaisessa roolissa kysyntä ja kysynnän ennustaminen on toimialalla. Jotta lukija ymmärtäisi vaateteollisuuden toimintaa, perehdytään luvussa tarkemmin vaateteollisuuden toimitusketjuihin. Neljännessä luvussa selvitetään, mistä lähteistä vaateteollisuudessa toimivat yritykset voivat kerätä dataa sekä perehdytään aikaisempiin tutkimuksiin siitä, miten kysynnän ennustamista voidaan tukea vaateteollisuudessa data-analytiikan menetelmien avulla. Lopuksi viidennessä eli työn viimeisessä luvussa käydään läpi työssä saavutetut tulokset ja johtopäätökset. Taulukon 1 avulla havainnollistetaan työn rakennetta.

Taulukko 1. Työn rakenne

<b>Input</b>	<b>Luku</b>	<b>Output</b>
Aiheen esittely, tausta ja motivaatio	Johdanto	Tutkimuskysymykset, tavoitteet ja rajaukset
Kirjallisuus datasta, big datasta ja data-analytiikasta	Data-analytiikka	Data-analytiikkaan liittyvien käsitteiden avaaminen
Kirjallisuus vaateteollisuudesta ja sen toimitusketjuista sekä kysynnän ennustamisesta	Vaateteollisuus ja kysynnän ennustaminen	Vaateteollisuuden ominaispiirteet, toimitusketjujen rakenne sekä kysynnän ennustamisen merkitys
Tutkimustieto datan hyödyntämisestä kysynnän ennustamisessa vaateteollisuudessa	Kysynnän ennustaminen data-analytiikan avulla vaateteollisuudessa	Datan lähteet, selvitys data-analytiikan hyödyntämismahdollisuuksista kysynnän ennustamisessa vaateteollisuudessa
Aikaisempien lukujen tulokset ja havainnot	Johtopäätökset	Tutkimuskysymyksiin vastaukset

## 2 Data-analytiikka

Tässä luvussa perehdytään data-analytiikkaan ja siihen liittyviin käsitteisiin. Aluksi käydään läpi datan määritelmä. Tämän jälkeen tarkastellaan big dataa ja sen ominaisuuksia. Lopuksi käsitellään data-analytiikkaa.

### 2.1 Datan määritelmä

Tässä työssä data ja sen analysoiminen on keskeisessä osassa, minkä takia datan määritelmän ymmärtäminen on tärkeää. Liewin (2007) mukaan data on kerättyjä ja tallennettuja symboleja ja lukemia, jotka voivat olla esimerkiksi numeroita, tekstiä, kaavioita, kuvia tai sensorilukemia. Datalla ei ole yksinään arvoa, vaan siitä tulee arvokasta vasta silloin, kun sitä osataan hyödyntää sopivassa kontekstissa. Oikein hyödynnettynä data onkin tärkeä arvonlähde yrityksille. (Müller & Jensen, 2017) Datan hyödyntämisellä tarkoitetaan, että sitä analysoidaan, visualisoidaan sekä käytetään apuna erilaisten päätösten tekemisessä (Miller & Mork, 2013).

Dataa syntyy lukemattomista lähteistä ja usein myös reaaliajassa (Miller & Mork, 2013). Data voi olla rakenteeltaan strukturoitua, strukturoimatonta tai osittain strukturoitua. Strukturoitu eli rakenteellinen data on taulukkomuodossa olevaa dataa, jota saadaan laskentataulukoista ja relaatiotietokannoista. Strukturoitu data on näin jo valmiiksi tietokoneelle helposti ymmärrettävässä muodossa olevaa dataa, mikä helpottaa sen analysoimista ja hyödyntämistä. Strukturoimaton eli rakenteeton data ei puolestaan nimensä mukaisesti omaa selkeää rakennetta, ja se voi olla tekstin, äänitiedostojen, kuvien ja videoiden muodossa olevaa dataa. Tämän vuoksi sen analysoiminen ja hyödyntäminen on lähtökohtaisesti haastavampaa, kuin strukturoidun datan. Strukturoidun ja strukturoimattoman datan lisäksi on olemassa myös osittain strukturoitua dataa. Osittain strukturoitua dataa ovat esimerkiksi XML-tiedostot. (Gandomi & Haider, 2015)

## 2.2 Big data

Big data on herättänyt paljon kiinnostusta viime vuosina niin yrityksissä kuin mediassakin. Sen kiinnostavuutta sekä sen tuomia hyötyjä voidaan selittää sen ominaisuuksien avulla. Näitä big datan ominaisuuksia kuvataan usein 3V-mallin avulla. Malli pitää sisällään datan määrän (volume), nopeuden (velocity) ja monimuotoisuuden (variety). (Gandomi & Haider, 2015)

Datan määrällä viitataan olemassa olevan datan suureen määrään. Big datan suuresta koosta kertoo se, että se ilmoitetaan useissa teratavuissa ja petatavuissa. Suuruuden puolesta big dataksi luokiteltavan datan määritelmä ei ole sama kaikilla toimialoilla ja siihen vaikuttaa lisäksi aika ja tarkastelun kohteena oleva datatyyppe. (Gandomi & Haider, 2015)

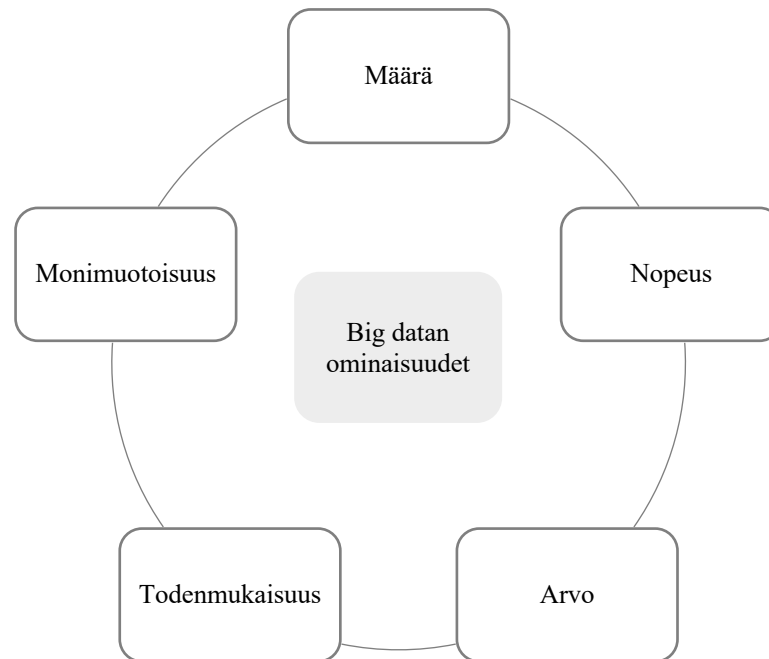
Datan nopeudella kuvataan puolestaan datan syntynopeutta sekä sitä nopeutta, jolla datasta saadaan analysoinnin avulla informaatiota, jota voidaan hyödyntää esimerkiksi päätöksenteossa. Teknologian kehitys ja digitalisaatio ovat johtaneet siihen, että uutta dataa syntyy entistä nopeammin. (Gandomi & Haider, 2015) Tämä on tehnyt mahdolliseksi reaaliaikaisen datan hyödyntämisen yritystoiminnoissa (McAfee et al., 2012).

Datan monimuotoisuudella viitataan datan rakenteelliseen vaihtelevuuteen. Eri lähteistä saatava big dataksi luokiteltava data voi olla strukturoitua, strukturoimatonta tai osittain strukturoitua. Suurin osa olemassa olevasta big datasta on kuitenkin strukturoimatonta dataa ja arvioiden mukaan vain pieni osa on valmiiksi analysoitavassa muodossa olevaa strukturoitua dataa. (Gandomi & Haider, 2015) Suuria määriä dataa syntyy erilaisten älypuhelimien, mobiililaitteiden ja sosiaalisen median käytöstä. Dataa syntyy jatkuvasti esimerkiksi kuvien, viestien ja erilaisten päivitysten muodossa. (McAfee, Brynjolfsson, Davenport, Patil & Barton, 2012) Big dataa on mahdollista kerätä sosiaalisen median ja internetin datalähteiden lisäksi esimerkiksi erilaisten sensorien, tutkimusten ja havaintojen avulla (Jin, Wah, Cheng & Wang, 2015). Big data ei siis ole vain tietyn muotoista dataa, vaan sitä voidaan kerätä erityyppisistä lähteistä ja erimuotoisena.

Edellä esitettyjen kolmen ominaispiirteen lisäksi big dataa voidaan kuvata myös muiden ominaispiirteiden avulla. Big datan ominaisuuksia voidaan kuvailla 3V-mallin lisäksi 5V-



mallin avulla (kuva 1). 5V-malli sisältää edellä mainittujen ominaisuuksien lisäksi todenmukaisuuden (veracity) ja arvon (value). Big datan ominaisuutena todenmukaisuuden katsotaan olevan alhainen, sillä datan oikeellisuuden ja luotettavuuden tunnistaminen voi olla haastavaa. Big datan katsotaan olevan lisäksi erittäin arvokasta, minkä takia arvo voidaan lisätä sen määritelmään viidenneksi ominaisuudeksi. (Jin et al., 2015)



Kuva 1. Big datan ominaisuudet (mukaiillen Gandomi & Haider, 2015; Jin et al., 2015)

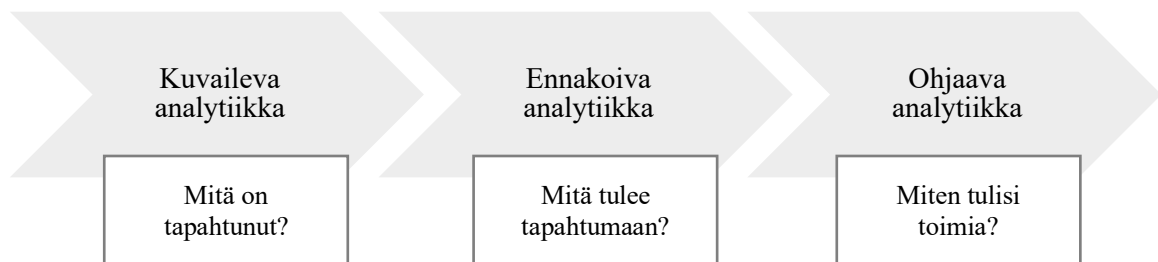
Erittäin suurten datamäärien avulla on mahdollista tunnistaa erilaisia trendejä, assosiaatioita ja kaavoja (Hack-Polay, Rahman, Billah & Al-Sabbahy, 2020). Big data ei kuitenkaan automaattisesti tuo lisäarvoa organisaatiolle. Big datan käsitteleminen ja sen sisältämien tietojen ymmärtäminen ja hyödyntäminen edellyttää data-analytiikan työkalujen ja menetelmien käyttöönottoa. (Buhl, Röglinger, Moser & Heidemann, 2013; Evans, 2015)

### 2.3 Data-analytiikka

Jotta dataa voidaan hyödyntää päätöksenteossa, tulee sitä ensin käsitellä ja analysoida. Tämä tapahtuu data-analytiikan avulla. Runklerin (2016, s. 2) mukaan data-analytiikalla tarkoitetaan päätöksenteon tueksi tehtävää suurten tietoaaineistojen analysoimista erilaisten

tietokonejärjestelmien avulla. Analysoimista tukevien menetelmien hyödyntäminen liiketoiminnassa ei ole uusi asia, vaan niitä on hyödynnetty jo pitkään. Analytiikan menetelmät alkoivat kuitenkin kehittyä nykyajan menetelmiksi vasta tietokoneiden käyttöönoton ja kehityksen myötä. Tietokoneet mahdollistivat kokonaan uuden tavan käsitellä ja analysoida dataa. (Evans, 2015)

Analytiikan hyötyjen ja tekniikoiden ymmärtäminen on tärkeää menestyneen liiketoiminnan näkökulmasta. Analytiikkaa on mahdollista hyödyntää monissa eri yritystoiminnoissa. Sitä voidaan hyödyntää niin tuotteiden valmistuksessa, tuotannon suunnittelussa kuin myös tuotteiden markkinoinnissa. (Evans, 2015) Hyödyntämiskohde vaikuttaa siihen, mitä analytiikkamenetelmää käytetään. Analytiikka voidaan jakaa kuvailevaan, ennakoivaan ja ohjaavaan analytiikkaan (kuva 2). (Delen & Demirkan, 2013)



Kuva 2. Data-analytiikan luokittelu (mukaillen Delen & Demirkan, 2013)

Kuvailevan analytiikan avulla voidaan selvittää, mitä on tapahtunut aikaisemmin. Data esitetään selkeässä ja ymmärrettävässä muodossa esimerkiksi erilaisten taulukoiden, kaavioiden ja karttojen avulla. (Rajaraman, 2016) Kuvailevan analytiikan avulla voidaan tunnistaa liiketoimintamahdollisuuksia ja erilaisia ongelmia (Delen & Demirkan, 2013).

Ennakoivan analytiikan avulla voidaan selvittää asiakkaiden tarpeita ja mieltymyksiä (Rajaraman, 2016). Näin ollen sitä voidaan hyödyntää myös kysynnän ennustamisessa (Souza, 2014). Datan analysoimisessa käytettävien matemaattisten tekniikoiden avulla voidaan tunnistaa erilaisia selittäviä ja ennakoivia malleja, kuten trendejä ja assosiaatioita aineistosta. Ennakoivassa analytiikassa voidaan hyödyntää esimerkiksi tekstinlouhintaa, tiedonlouhintaa sekä aikasarjaennustamista. Ennakoivan analytiikan päätavoite on paikkansapitävä ennuste

siitä, mitä tulee tapahtumaan tulevaisuudessa sekä selvitys siitä, miksi näin ajatellaan tapahtuvan. (Delen & Demirkan, 2013)

Ohjaavaa analytiikkaa voidaan käyttää, kun halutaan optimoida päätöksentekoa tai selvittää paras mahdollinen toimintamenetelmä. Ohjaavan analytiikan tekniikat perustuvat datan ja matemaattisten algoritmien hyödyntämiseen. Nämä matemaattiset algoritmit voivat hyödyntää dataa, asiantuntijaosaamista tai kumpaakin yhdessä. Ohjaavassa analytiikassa voidaan käyttää hyödyksi esimerkiksi simulointimallinnusta, optimointimallinnusta, monikriteeristä päätöksentekomallinnusta tai asiantuntijajärjestelmiä. (Delen & Demirkan, 2013)

### 3 Vaateteollisuus ja kysynnän ennustaminen

Tässä luvussa käsitellään vaateteollisuuden ominaispiirteitä, toimitusketjuja sekä kysynnän ennustamista. Aluksi käydään läpi kysynnän luonteen ymmärtämiseksi vaateteollisuuden ominaispiirteitä. Tämän jälkeen perehdytään vaateteollisuuden toimitusketjujen rakenteeseen. Lopuksi luvussa käsitellään kysynnän ennustamista ja onnistuneen ennustamisen tärkeyttä.

#### 3.1 Vaateteollisuuden ominaispiirteet

Vaateteollisuus keskittyy vaatteiden ja asusteiden valmistamiseen. Se on hyvin kansainvälinen teollisuudenala ja yksi tärkeimmistä taloudellisista sektoreista, sillä sen tuottamat vaatteet kuuluvat ihmisten jokapäiväiseen elämään. (Guo, Wong, Leung & Li, 2011) Alalla toimii lukuisia eri yrityksiä, mutta sitä dominoivat suuret ja tunnetut globaalit yritykset (Smith, 2022).

Vaateteollisuuteen liitetään paljon erilaisia ominaispiirteitä, jotka vaikuttavat sen toimintaan. Vaateteollisuuden ominaispiirteisiin kuuluu suuri ja nopeasti vaihtuva tuotevalikoima. Vaatteita on saatavilla eri mallien ja tyylien lisäksi eri väreissä ja kokovaihtoehdoissa. Suunnittelultaan saman vaatekappaleen valmistaminen eri kokovaihtoehdoissa ja väreissä lisää lopputuotteiden määrää. (Thomassey, 2010) Nopeasti vaihtuva tuotevalikoima on puolestaan seurausta nopeasti vaihtuvista vaatetreendeistä. Vaatetrendit vaihtelevat paljon, mikä lisää vaateteollisuuden yrityksille paineita valmistaa jatkuvasti uusia tuotteita nopeasti markkinoille. (Sull & Turconi, 2008) Kuluttajat hankkivat uusia vaatteita vaatetrendien vaihtuessa ja tämän seurauksena myös vaatteiden käyttöikä on lyhentynyt (Mahmood & Kess, 2016). Vaateteollisuudesta puhuttaessa puhutaankin usein myös pikamuodista. Pikamuoti on konsepti, jota noudattavien yritysten tavoitteena on tuoda nopeasti kuluttajien saataville uusia tuotteita ja päivittää tuotevalikoimaa useasti kauden aikana (Barnes & Lea-Greenwood, 2010). Tämä johtaa siihen, että vaatteita tuotetaan ja kulutetaan paljon, ja tämän takia pikamuotiteollisuuden synnyttämistä vaatejätteistä on tullut iso yhteiskunnallinen ongelma (Shim, Kim & Na, 2018). Pikamuotiteollisuuteen liitettäviä ongelmia ovat lisäksi suuri vedenkulutus, vaarallisten kemikaalien aiheuttamat päästöt, ihmisoikeusloukkaukset sekä kasvihuonekaasupäästöt (Gazzola, Pavione, Pezzetti & Grechi, 2020).

Muotitrendien nopean vaihtuvuuden takia useimmat tuotteet ovat myynnissä vain hetken ajan ja niitä ei tuoteta uudestaan seuraavalle kaudelle. Tuotteiden kertaluonteisuuden ja lyhyen myyntiajan takia historiallisten myyntitietojen kerääminen sekä hyödyntäminen on haastavaa. (Thomassey, 2010) Vaateteollisuudessa tuotteiden kysyntä on muutenkin hyvin epävakaa ja vaihtelevaa ja siihen voi vaikuttaa esimerkiksi sääolosuhteet, vuodenaajat, trendit ja tunnetut henkilöt (Sull & Turconi, 2008). Kysynnän ennustettavuutta hankaloittaa lisäksi se, että kuluttajat ostavat vaatteita usein impulsiivisesti (Mahmood & Kess, 2016). Kysyntään vastaamista vaikeuttaa lisäksi vaateteollisuuden pitkät ja jäykät toimitusprosessit sekä monimutkaiset toimitusketjut (Sen, 2008).

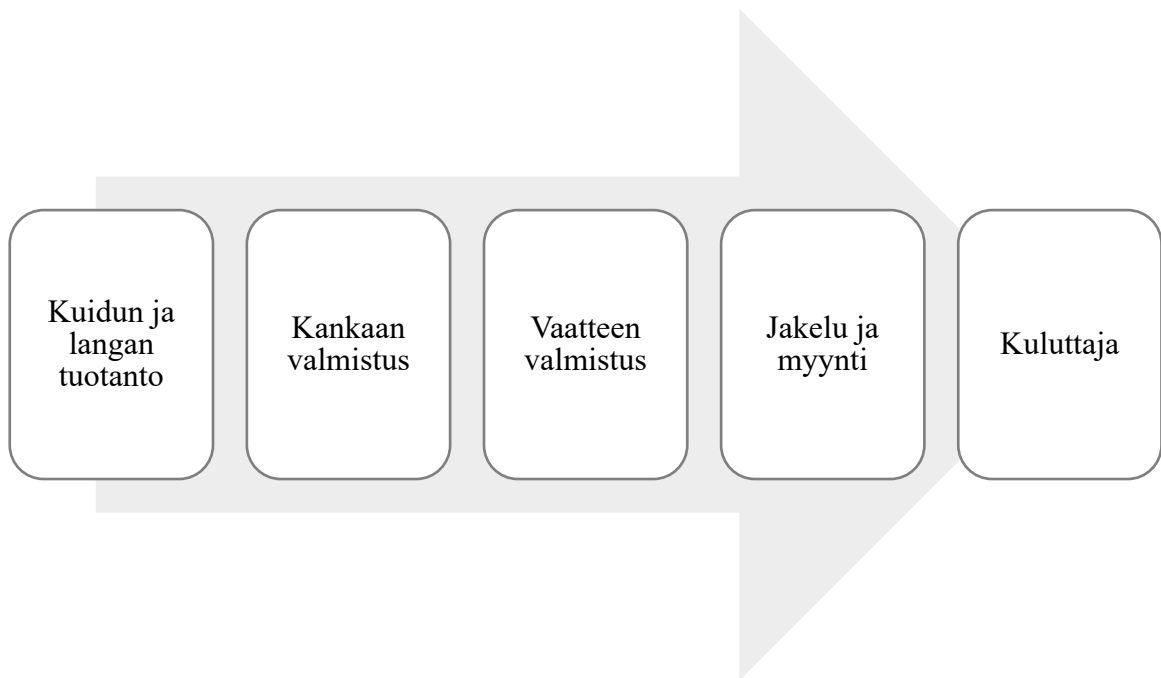
### 3.2 Toimitusketjut vaateteollisuudessa

Tuotteen toimitusketjun tarkoituksena on valmistaa raaka-aineesta valmis lopputuote ja toimittaa tämä jakeluun asiakkaille (Souza, 2014). Vaateteollisuudessa voidaan hyödyntää erilaisia toimitusketjustrategioita. Yleisesti hyödynnetyt strategiat ovat perinteinen strategia ja pikamuotistrategia. (Backs, Jahnke, Lüpke, Stücken & Stummer, 2020)

Perinteinen toimitusketjustrategia on hidas ja siinä on tyypillisesti pitkät toimitusajat, koska tuotanto keskittyy pitkien toimitusmatkojen päissä sijaitseviin matalapalkkaisiin maihin (Backs et al., 2020). Tässä strategiassa tuotteen läpimenoaika suunnittelusta myyntiin voi olla esimerkiksi kuuden kuukauden tai jopa kokonaisen vuoden pituinen (Cachon & Swinney, 2011). Pitkät toimitusajat heikentävät toimitusketjun joustavuutta. Toimitusketjun hitauden takia myyntiennusteet joudutaan tekemään pitkällä tähtäimellä etukäteen. Tarkkojen ennusteiden tekeminen pitkän ajan päähän on vaikeaa ja aiheuttaa tämän vuoksi kysynnän ennustamisen epätarkkuutta. Koska kysyntä on vaikea arvioida etukäteen pitkän ajan päähän, tuotetaan helposti ylijäämää. Perinteisessä strategiassa tuotteita hankitaan suurissa erissä valmistajilta. Tavoitteena on vastata koko myyntikauden arvioituun kysyntään ja välttää varaston loppumista, jotta voitaisiin myydä mahdollisimman paljon tuotteita. Tämän strategian etuna ovat suuresta tuotannosta syntyvät skaalaedut ja pienemmät kustannukset. (Backs et al., 2020)

Pikamuotistrategia pitää sisällään kaksi eri tuoteluokkaa, jotka ovat perustuotteet ja muotituotteet. Perustuotteiden hankinnassa käytetään edellä esitettyä perinteistä strategiaa, kun taas muotituotteiden hankinnassa vaatteet tuotetaan lähempänä niiden myyntipaikkaa, mikä mahdollistaa lyhyet toimitusajat ja joustavan toiminnan. Pikamuotistrategian etuna onkin nimenomaan toimitusketjun joustavuus ja lyhyet toimitusajat. Tuotantokustannukset ovat tässä strategiassa kuitenkin suuremmat kuin perinteisessä strategiassa, sillä vaatteet tuotetaan suurempien työvoimakustannusten maissa. (Backs et al., 2020) Strategiaa noudattavien yritysten tuotteiden läpimenoajat suunnittelusta myyntiin ovat lyhyitä, ja ne voivat olla vain muutaman viikon pituisia (Cachon & Swinney, 2011). Pikamuotistrategiassa kysyntäennusteet voidaan tehdä lyhyellä aikavälillä, mikä mahdollistaa ajankohtaisen datan hyödyntämisen. Pikamuotistrategiassa tuotteita hankitaan pienemmissä erissä kuin perinteisessä strategiassa ja niitä tarjotaan kuluttajille myös lyhyemmän ajan. Pikamuotistrategian tavoitteena on reagoida kuluttajien kysyntään nopeasti ja joustavasti ja tarjota vallitsevien trendien mukaisia tuotteita. (Backs et al., 2020)

Tekstiilien ja vaatteiden toimitusketjut ovat tyypillisesti monimutkaisia ja ne pitävät sisällään eri tuotannonvaiheita ja toimijoita (Agrawal, Kumar, Pal, Wang & Chen, 2021). Tyypillinen toimitusketju lähtee raaka-aineen tuottamisesta, mistä se etenee tekstiilin ja kankaan tuotantoon. Tekstiilin ja kankaan tuotannosta se etenee vaatteiden valmistukseen ja lopulta vaatteiden jakeluun ja myyntiin kuluttajille. (Sen, 2008) Tekstiilien ja vaatteiden toimitusketjun osia havainnollistaa kuva 3.



Kuva 3. Tekstiilien ja vaatteiden toimitusketju (mukaillen Sen, 2008; Agrawal et al., 2021)

Kuidun ja langan tuotannossa valmistetaan ne materiaalit, joita käytetään tekstiilien ja vaatteiden valmistuksessa. Käsiteltävät kuidut voivat olla luonnonmukaisia tai keinotekoisia. (Sen, 2008) Luonnonmukaisia kuituja ovat esimerkiksi puuvilla, villa ja silkki. Keinotekoisia kuituja ovat esimerkiksi polyesteri, nailon ja akryyli. (Chen, Memon, Wang, Marriam, & Tebyetekerwa, 2021) Näistä kuiduista valmistetaan lankaa erilaisten menetelmien ja välineiden avulla (Sen, 2008).

Kankaan tuotannossa hyödynnetään ensimmäisessä vaiheessa tuotettuja lankoja ja valmistetaan kankaita ja tekstiilejä. Kankaita voidaan valmistaa kutomalla, neulomalla ja kuitukan-gasprosessin avulla. (Sen, 2008) Kankaan valmistusprosessi pitää usein sisällään kankaiden esikäsittelyn, värjäyksen ja viimeistelyn (Mahmood & Kess, 2016).

Valmiit kankaat lähetetään eteenpäin vaatteiden valmistajille, jotka tekevät kankaista vaatteita (Agrawal et al., 2021). Vaatteiden tuotanto lähtee liikkeelle vaatteiden suunnittelusta ja etenee kaavojen tekemiseen ja siitä kankaan leikkaamiseen. Leikatuista paloista voidaan omella vaatteet, jotka merkitään ja lähetetään eteenpäin. (Sen, 2008)

Lopulta valmiit vaatteet tulevat kuluttajien saataville vähittäiskauppoihin (Sen, 2008). Vähittäiskauppojen ja vaatebrändien rooli vaatteiden toimitusketjussa on merkittävä, sillä ne ovat vastuussa tuotekehitysprosessista ja siten myös tilausten tekemisestä toimitusketjun alkupään yrityksille sekä valmiiden tuotteiden toimittamisesta kuluttajille (Cao, Zhang, To & Ng, 2008; Thomassey, 2010). Vaatteita myyviä vähittäiskauppoja on paljon erilaisia ja ne toimivat eri ratkaisulla. Vaatteisiin erikoistuvat vähittäiskaupat erikoistuvat usein tiettyyn markkinasegmenttiin. Vaatteita voidaan myydä niin kivijalkakaupoissa kuin myös verkko-kaupoissa. (Sen, 2008) Verkkokaupat ovat nykyään suosittu vaihtoehto asiakkaiden keskuudessa. Verkosta ostaminen on asiakkaiden näkökulmasta kätevää, sillä ostoksia voi tehdä milloin vaan ja mistä vaan ilman, että tarvitsisi käyttää aikaa tai rahaa matkustamiseen. Etuna on lisäksi suuri tuotevalikoima ja usein on myös mahdollista tehdä hintavertailua ja säästää näin ostoksia tehdessä. (Suthamathi & Jeeva, 2020)

Edellä esitetty toimitusketju on yksinkertaistettu versio tekstiilien ja vaatteiden toimitusketjusta. Todellisuudessa tähän toimitusketjuun kuuluu lisäksi useita alihankkijoita ja urakoitsijoita, jotka ovat vastuussa lisäosien, kuten nappien tuottamisesta, sekä erilaisten prosessointipalveluiden kuten kemikaalisten käsittelyiden tarjoamisesta (Agrawal et al., 2021). Kemikaalitoimittajat ovat hyvin merkittävässä roolissa tekstiilien ja vaatteiden toimitusketjun eri vaiheissa, ja ne vaikuttavat suoraan esimerkiksi tuotteen laatuun (Mahmood & Kess, 2016).

Vaateteollisuus toimii lähes kokonaan lineaarisesti tuotannon, jakelun ja käytön suhteen. Toisin sanoen raakamateriaaleista edetään tuotantoon, tuotannosta käyttöön ja käytön jälkeen vaatteet hävitetään. Tällainen lineaarinen malli on haitallinen ympäristölle, ja tämän lisäksi se rasittaa yhteiskuntien taloutta ja jättää monia taloudellisia mahdollisuuksia hyödyntämättä. Vaatteista puhuttaessa on hyvä ottaa huomioon se, että niitä on mahdollista myös kierrättää ja uusiokäyttää. Käytettyjä vaatteita voidaan esimerkiksi jälleenmyydä tai vuokrata ja näin pidentää niiden käyttöikää ja vähentää ympäristöön kohdistuvaa kuormitusta. (Chen et al., 2021)



### 3.3 Kysynnän ennustaminen

Kysynnän ennustaminen on keskeisessä osassa kysynnän hallinnan prosessia. Kysynnän hallinnan prosessi keskittyy asiakkaiden tarpeiden ja toimitusketjun kapasiteetin tasapainottamiseen. Hyvä kysynnän hallinnan prosessi mahdollistaa odotettavissa olevaan kysyntään vastaamisen lisäksi myös odottamattomaan kysyntään vastaamisen. (Croxtton, Lambert, García-Dastugue & Rogers, 2002) Kysynnän hallinta tukee näin toimitusketjun toimintaa ja parantaa sen suorituskykyä (Rexhausen, Pibernik & Kaiser, 2012).

Kysynnän ennustamisessa tärkeää on oikean ennustamismenetelmän valinta. Oikean ennustamismenetelmän valinta edellyttää sopivien datalähteiden määrittämisen, ennusteiden aikavälin ja tason määrittämisen sekä ennustamisen toteutustavan määrittelyn vaadittavalle ennusteelle. Datalähteiden valinnassa tärkeää on tunnistaa, mitkä lähteet ovat hyödyllisiä ennustamisen näkökulmasta, ja tuovat sille lisäarvoa. Kysynnän ennustamisen jälkeen tehdään suunnitelma siitä, miten kysyntään vastataan. Ennustamismenetelmien toimivuutta kysynnän ennustamisessa kannattaa arvioida niiden käyttöönoton jälkeen ja tarvittaessa muuttaa, jos esimerkiksi kysynnän luonteessa tapahtuu muutoksia tai jos ennustevirheet kasvavat. (Croxtton et al., 2002)

Tarkan ennustetuloksen saaminen voi kuitenkin olla haastavaa. Epätarkat ennusteet voivat johtaa ylituotantoon ja ylivarastoihin tai alituotantoon ja alivarastoihin (Fisher & Raman, 1996; Nenni et al., 2013). Ylituotanto johtaa valmistusmateriaalien ja energiaressurssien tuhlaamiseen sekä ylimääräisten päästöjen ja jätteiden syntymiseen (Vinodh, Arvind & Somanathan, 2011). Epätarkkojen ennusteiden takia voi syntyä ylimääräisiä varastonpitokustannuksia ja kuljetuskustannuksia. Kustannuksia voi aiheutua lisäksi varaston vanhentumisesta. Varaston ylijäämä voi johtaa tuotteiden alennusmyynteihin. (Kenneth, 2003) Vaateteollisuudessa erityisesti ylituotanto on suuri ongelma, sillä suuri osa sen tuotannosta on ylituotantoa (Magnusdottir, 2020).

Alituotanto ja alivarastot puolestaan voivat aiheuttaa kiirehtimiskustannuksia sekä nostaa tuotekohtaisia kustannuksia. Kysynnän aliarvioinnin seurauksena asiakkaiden kysyntään ei pystytä vastaamaan. Tämä johtaa menetetyyn myynnin aiheuttamiin kustannuksiin ja asiakkaiden tyytymättömyyteen. (Kenneth, 2003)

Kysynnän ennustaminen on siis tärkeässä roolissa kysynnän ja tarjonnan tasapainottamisessa. Epätarkat ja virheelliset kysyntäennusteet aiheuttavat ylimääräisiä kustannuksia. Tämän takia vaateteollisuuden yritysten on aiheellista panostaa kysynnän ennustamiseen ja löytää ratkaisuja lähtökohtaisesti vaikeasti ennustettavan kysynnän ennustamiseen.

## 4 Kysynnän ennustaminen data-analytiikan avulla vaateteollisuudessa

Tässä luvussa selvitetään, miten data-analytiikkaa voidaan hyödyntää kysynnän ennustamisessa vaateteollisuudessa. Aluksi perehdytään siihen, mistä lähteistä dataa voidaan kerätä vaateteollisuuden käyttöön. Tämän jälkeen selvitetään, miten kysynnän ennustamisessa voidaan hyötyä datasta ja sen analysoimisesta.

### 4.1 Datan lähteet vaateteollisuudessa

Dataa voidaan kerätä monista eri lähteistä vaateteollisuuden hyötykäyttöön. Lähteet voivat olla yrityksen sisäisiä sekä myös ulkoisia lähteitä. Yritykset voivat kerätä dataa myyntitapahtumista tai taloudellisista tiedoista. Dataa voidaan kerätä myös esimerkiksi sosiaalisesta mediasta ja hakukoneista. Verkkokauppaympäristössä toimivat yritykset voivat kerätä dataa lisäksi verkkokauppa-alustoilta. (See-To & Ngai, 2018)

Vaateteollisuuden yritykset voivat kerätä myyntitapahtumista saatavaa POS-dataa (point-of-sale) (Raza & Kilbourn, 2017). POS-datalla tarkoitetaan toimitusketjun viimeisessä vaiheessa saatavaa tietoa tuotteen myynnistä sen loppukäyttäjälle ja sen lähteenä on yleensä joko vähittäiskaupat tai kolmannet osapuolet. POS-datan avulla voidaan selvittää esimerkiksi aikaisemmin myytyjen tuotteiden määrä, minkä seurauksena sitä voidaan hyödyntää kysynnän ennustamisessa. (Simon, 2008)

Dataa voidaan kerätä ja analysoida myös sosiaalisesta mediasta, kuluttajien kommenteista ja asiakaspalautteista (See-To & Ngai, 2018; Ren, Chan & Siqin, 2019; Hack-Polay et al., 2020). Sosiaalinen media tuo kokonaan uuden mahdollisuuden kuluttajien käyttäytymisen analysoimiseen, sillä sen kautta ihmiset pystyvät ilmaisemaan ja jakamaan mielipiteitä ja ajatuksia helposti (Giri, Thomassey & Zeng, 2019). Sosiaalinen media tuottaa valtavia määriä erimuotoista dataa. Dataa voidaan saada esimerkiksi tekstin, kuvien, videoiden ja paikkatietojen muodossa. Sosiaalisesta mediasta saatavan datan analysoimisen avulla voidaan saada tietoa esimerkiksi erilaisista ongelmista sekä vallitsevista trendeistä. (Stieglitz, Mirbabaie, Ross & Neuberger, 2018)

Sosiaalisen median lisäksi vaateeteollisuudessa voidaan hyödyntää muitakin ulkoisia datalähteitä. Esimerkiksi sää voi vaikuttaa vaatteiden kysyntään ja säästä kertovaa, avoimista datalähteistä ja sääasemilta saatavaa meteorologista dataa voidaan hyödyntää vaateeteollisuudessa (Bertrand, Brusset & Fortin, 2015; Badorf & Hoberg, 2019). Myös talouden suhdannevaihtelut voivat vaikuttaa vaateeteollisuuteen ja vaatteiden kysyntään (Brazioti, 2013). Talouden tilan analysoimisessa voidaan hyödyntää erilaisia makroekonomisia indikaattoreita. Makroekonomisten indikaattoreiden avulla voidaan saada hyödyllistä tietoa esimerkiksi ihmisten ostovoimasta, resurssien kulutuksesta sekä väestön jakautumisesta ja vallitsevasta hintatasosta. (Zhang, Tian & Fan, 2020) Makroekonomista dataa voidaan saada valtioiden julkaisemista datalähteistä (Mukherjee, Panayotov & Shon, 2021).

#### 4.2 Data-analytiikka kysynnän ennustamisessa vaateeteollisuudessa

Vaateeteollisuuden tuotteista iso osa on uusia tuotteita, joita ei ole aikaisemmin valmistettu tai myyty. Tämän takia niistä puuttuu kokonaan historiadata, jota voitaisiin hyödyntää kysynnän ennustamisessa. Uusien tuotteiden kysynnän ennustamiseen on kuitenkin pyritty löytämään muita ratkaisuja. Kharfan, Chan & Efendigil (2020) kehittivät tekemässään tutkimuksessa kysynnän ennustamista uusille tuotteille, joista puuttuu historiallinen data. Heidän menetelmänsä perustuu koneoppimisen ja POS-datan hyödyntämiseen, ja tutkimuksessaan he esittävät kolmivaiheisen prosessin, joka pitää sisällään klusteroinnin, luokittelun ja ennustamisen. Prosessin tarkoituksena on tunnistaa tuoteryhmät, jotka ovat samankaltaisia keskenään. Tämän jälkeen voidaan hyödyntää vanhojen tuotteiden myyntidataa ja ennustaa uusien tuotteiden kysyntää. Ennustamisvaiheessa tutkimuksessa käytetyt menetelmät olivat satunnaismetsä, k:n lähimmän naapurin menetelmä, neuroverkot, päätöspuut ja lineaarinen regressio. Näiden lisäksi tutkimuksessa testattiin kokoonpanomenetelmien toimivuutta. Tutkimuksessa esiteltyä kolmivaiheista prosessia on tutkimuksen tulosten perusteella mahdollista hyödyntää uusien tuotteiden kysynnän ennustamisessa. (Kharfan et al., 2020)

Vaatteiden kysyntään vaikuttaa vallitsevat muotitrendit ja kuluttajien mieltymykset (Sull & Turconi, 2008; Sen, 2008). Kuluttajien mieltymyksistä on mahdollista saada tietoa sosiaalisesta mediasta saatavan datan analysoimisen avulla. An & Park (2020) selvittivät tekemässään tutkimuksessa, miten tekstinlouhinnan ja semanttisen verkkoanalyysin avulla voidaan analysoida sosiaalisesta mediasta saatavaa kuluttajälähtöistä dataa ja tunnistaa

muotitrendejä. Tutkimuksessa käytettävä data kerättiin blogijulkaisuista. Tulosten perusteella edellä mainittujen menetelmien avulla voidaan tunnistaa muotitrendejä ja selvittää kuluttajien mieltymyksiä. Nämä datan analysoimisessa käytetyt menetelmät ovat siten toimivia, ja niiden avulla voidaan analysoida kuluttajien mieltymyksiä erilaisiin muotisuunniteluihin tehokkaasti. (An & Park, 2020)

Myös moni vaateteollisuuden yritys on onnistunut hyödyntämään data-analytiikkaa kysynnän ennustamisessa. Hyvä esimerkki tehokkaasti liiketoiminnassaan dataa hyödyntävästä vaateteollisuuden yrityksestä on espanjalainen Inditex. Inditexiin kuuluvia brändejä ovat Zara, Pull&Bear, Massimo Dutti, Bershka, Stradivarius, Oysho ja Zara Home. Yritys kertoo vuoden 2019 vuosikertomuksessaan käyttävänsä koneoppimismalleja optimaalisen varastotason määrittämiseen kullekin myyntipisteelle. Alustavia ennusteita verrataan reaaliaikaiseen tilanteeseen ja tarjontaa säädetään tämän mukaan. Näiden menetelmien tavoitteena on parantaa kysyntään vastaamista, pienentää ylimääräistä varastoa sekä optimoida tuotantoprosessia. (Inditex, 2020)

Uusien tuotteiden kysynnän ennustamisen tarkkuuden parantamiseksi Inditex on kehittänyt yhteistyössä Massachusettsin teknillisen korkeakoulun kanssa tekoälyä hyödyntävän analyttisen hakukoneen. Tämä hakukone mahdollistaa vertailtavissa olevan tuotteen etsimisen uudelle tuotteelle, jolla ei ole historiadataa. Analyttisen hakukoneen avulla on mahdollista tehdä hyvinkin tarkkoja ennusteita ja näin parantaa kysynnän ennustamisen tarkkuutta. Kysynnän ennustamisen lisäksi Inditex hyödyntää dataa päätöksenteossa, logistiikka- ja kuljetusjärjestelmien kehittämisessä ja organisoinnissa, tuotteiden laadun varmistamisessa sekä toimitusketjun jäljitettävyyden takaamisessa. Dataa käytetään lisäksi riskien ennakoimiseen, prosessien kestävyys- ja tehokkuuden parantamiseen sekä asiakkaiden ostokokemuksen parantamiseen. (Inditex, 2020)

Työssä aikaisemmin esiteltiin epäonnistuneesta kysynnän ennustamisesta aiheutuvia seurauksia. Kysynnän yliarviointi voi johtaa esimerkiksi ylituotantoon, mikä erityisesti vaateteollisuudessa on suuri ongelma. Kirjallisuuskatsauksen perusteella tulevaa kysyntää on mahdollista ennustaa data-analytiikan menetelmien avulla, joten data-analytiikan hyödyntämisen etuna voidaan nähdä olevan myös ylituotannon ja varaston ylijäämän vähentäminen. Tämä taas pienentää ylimääräisten kuljetuskustannusten ja varastointikustannusten määrää.

Lisäksi tarkempien ennusteiden avulla on mahdollista vastata kuluttajien kysyntään paremmin ja varmistaa tuotteiden saatavuus.

Taloudellisten hyötyjen lisäksi onnistuneella data-analytiikan hyödyntämisellä kysynnän ennustamisessa voi olla myös hyötyä kestäväen kehityksen ja ympäristön kannalta. Vaate- ja tekstiiliteollisuutta pidetään yhtenä saastuttavimmista teollisuudenaloista koko maailmassa (Aus, Moora, Vihma, Unt, Kiisa & Kapur, 2021). Vaatteiden tuotanto vaatii huomattavia määriä energiaa ja luonnonvaroja (Shirvanimoghaddam, Motamed, Ramakrishna & Naebe, 2020). Ylituotanto kuluttaa turhaan resursseja, joten sen vähentäminen säästäisi valmistusmateriaaleja ja vähentäisi ympäristöä kuormittavien ylimääräisten resurssien kulutusta. Ylituotannon alentaminen voisi vähentää myös syntyvien jätteiden määrää sekä pienentää ylimääräisistä kuljetuksista aiheutuvia päästöjä.

## 5 Johtopäätökset

Työn tavoitteena oli selvittää data-analytiikan hyödyntämismahdollisuuksia kysynnän ennustamisessa vaateteollisuudessa. Työn alussa käytiin läpi datan, big datan ja data-analytiikan käsitteitä ja ominaisuuksia. Työssä perehdyttiin seuraavaksi vaateteollisuuden ominaispiirteisiin sekä toimitusketjuihin. Lisäksi käsiteltiin kysynnän ennustamista. Neljännessä luvussa selvitettiin datan lähteitä, joita voidaan hyödyntää vaateteollisuudessa sekä perehdyttiin siihen, miten data-analytiikkaa on mahdollista hyödyntää kysynnän ennustamisessa vaateteollisuudessa. Työn päätutkimuskysymys oli:

- *Miten data-analytiikkaa voidaan hyödyntää kysynnän ennustamisessa vaateteollisuudessa?*

Tutkimuksen osakysymykset olivat:

- *Mitkä ovat vaateteollisuuden ominaispiirteet?*
- *Mistä lähteistä vaateteollisuudessa hyödynnettävää dataa voidaan kerätä?*

Vaateteollisuuden ominaispiirteet vaikuttavat siihen, minkä takia kysynnän ennustaminen on haastavaa mutta myös samalla tärkeää. Vaateteollisuuden tuotevalikoima on suuri ja se vaihtuu usein. Suuri osa myytävistä tuotteista on uusia tuotteita, joista ei ole saatavilla historiadataa, jota voitaisiin hyödyntää kysynnän ennustamisessa. Tuotteiden kysyntä on epävakaa ja vaihtelee esimerkiksi sään ja erilaisten muotitrendien vaikutuksesta. Kuluttajien kysyntään ja vaihteleviin muotitrendeihin pyritään vastaamaan pikamuodin avulla. Pikamuoti kasvattaa paineita toimitusketjulle ja edellyttää sen joustavaa toimintaa. Pikamuoti myös lyhentää aikoja suunnittelusta myyntiin, minkä takia ajankohtaisen datan hyödyntäminen on mahdollista kysynnän ennustamisessa.

Dataa voidaan kerätä yrityksen sisäisistä sekä ulkoisista lähteistä. Vaateteollisuudessa hyödynnettävää dataa voidaan kerätä monista eri lähteistä, kuten myyntitapahtumista, internetistä ja sosiaalisesta mediasta. Sosiaalinen media tuottaa valtavia määriä erimuotoista dataa, jota analysoimalla voidaan saada tietoa esimerkiksi kuluttajien mieltymyksistä. Myyntitapahtumista saatavan POS-datan avulla on mahdollista selvittää myytyjen tuotteiden määrä,

ja tätä tietoa voidaan hyödyntää kysynnän ennustamisessa. Verkkokauppaympäristössä toimivat vaatekaupat voivat kerätä ja analysoida lisäksi verkkokauppa-alustoilta saatavaa dataa. Avoimia datalähteitä voidaan hyödyntää esimerkiksi makroekonomisen datan sekä meteorologisen datan keräämisessä.

Kysynnän ennustamisen näkökulmasta suurena ongelmana vaatealudessa on historiadatan puute. Iso osa myytävistä tuotteista on uusia, minkä takia näistä ei ole usein saatavilla aikaisempia myyntitietoja tai muuta dataa. Data-analytiikan avulla voidaan kuitenkin ennustaa näidenkin tuotteiden kysyntää niin, että hyödynnetään jo myynnissä olleiden samankaltaisten tuotteiden historiadataa. Data-analytiikan avulla on lisäksi mahdollista tunnistaa muotitrendejä sekä analysoida kuluttajien mieltymyksiä sosiaalisesta mediasta saatavan datan avulla. Kuluttajien mieltymysten selvittäminen ja muotitrendien tunnistaminen voivat auttaa yrityksiä tarjoamaan myyntiin sellaisia tuotteita, joista asiakkaat ovat kiinnostuneita ja joille on kysyntää. Data-analytiikan menetelmät voivat hyödyntää erityisesti pikamuotiyrityksiä, sillä lyhyiden läpimenoaikojen takia nämä yritykset pystyvät hyödyntämään ajankohtaista dataa ja reagoimaan kuluttajien mieltymyksiin sekä muotitrendeihin nopeasti.

Vaateteollisuuden yritykset voivat saavuttaa erilaisia hyötyjä kysynnän ennustamisen avulla. Toimivan kysynnän ennustamismenetelmän käyttö mahdollistaa ylituotannon vähentämisen sekä varastotasojen alentamisen. Tämä taas pienentää ylimääräisiä varastointikustannuksia sekä ylimääräisten kuljetusten aiheuttamia kustannuksia. Onnistunut kysynnän ennustaminen voi myös vähentää menetetyn myynnin määrää ja parantaa yrityksen kykyä vastata kuluttajien kysyntään. Taloudellisten hyötyjen lisäksi kysynnän ennustamisen avulla voidaan saavuttaa hyötyjä myös kestävä kehityksen ja ympäristön näkökulmasta. Ylituotannon vähentäminen voi laskea ylimääräisten valmistusmateriaalien sekä ympäristöä kuormittavien resurssien kulutusta, vähentää syntyvien jätteiden määrää sekä pienentää ylimääräisistä kuljetuksista aiheutuvia päästöjä.

Kirjallisuuskatsauksen perusteella data-analytiikkaa voidaan hyödyntää kysynnän ennustamisessa vaatealudessa ja kysynnän ennustamista on mahdollista tukea eri analytiikkamenetelmiä sekä datalähteitä hyödyntämällä. Ulkoisista datalähteistä saatavan datan hyödyntämistä kysynnän ennustamisessa voisi selvittää vielä laajemmin. Esimerkiksi talouden suhdannevaihteluiden ja sään on todettu vaikuttavan vaatteiden kysyntään, minkä takia



jatkotutkimus voisi selvittää, miten makroekonomisen datan sekä meteorologisen datan analysoiminen voisi tukea kysynnän ennustamista vaateollisuudessa.

## Lähteet

Agrawal, T. K., Kumar, V., Pal, R., Wang, L. & Chen, Y. (2021). Blockchain-based framework for supply chain traceability: A case example of textile and clothing industry. *Computers & Industrial Engineering*, 154.

An, H. & Park, M. (2020). Approaching fashion design trend applications using text mining and semantic network analysis. *Fashion and Textiles*, 7 (1), 1-15.

Aus, R., Moora, H., Vihma, M., Unt, R., Kiisa, M. & Kapur, S. (2021). Designing for circular fashion: integrating upcycling into conventional garment manufacturing processes. *Fashion and Textiles*, 8 (1), 1-18.

Backs, S., Jahnke, H., Lüpke, L., Stücken, M. & Stummer, C. (2020). Traditional versus fast fashion supply chains in the apparel industry: an agent-based simulation approach. *Annals of Operations Research*, 305 (1-2), 487-512.

Badorf, F. & Hoberg, K. (2019). The impact of daily weather on retail sales: An empirical study in brick-and-mortar stores. *Journal of Retailing and Consumer Services*, 52.

Barnes, L. & Lea-Greenwood, G. (2010). Fast fashion in the retail store environment. *International Journal of Retail & Distribution Management*, 38 (10), 760-772.

Bertrand, J.-L., Brusset, X. & Fortin, M. (2015). Assessing and hedging the cost of unseasonal weather: Case of the apparel sector. *European Journal of Operational Research*, 244 (1), 261-276.

Brazioti, A. (2013). The Financial Development of the Greek Apparel Industry during the Crisis. *International Journal of Economics & Business Administration*, 1 (4), 66-79.

Buhl, H. U., Röglinger, M., Moser, F. & Heidemann, J. (2013). Big Data: A Fashionable Topic with(out) Sustainable Relevance for Research and Practice? *Business & Information Systems Engineering*, 5 (2), 65-69.

Cachon, G. P. & Swinney, R. (2011). The Value of Fast Fashion: Quick Response, Enhanced Design, and Strategic Consumer Behavior. *Management Science*, 57 (4), 778-795.

Cao, N., Zhang, Z., To, K. & Ng, K. (2008). How are supply chains coordinated? An empirical observation in textile-apparel businesses. *Journal of Fashion Marketing and Management*, 12 (3), 384-397.

Chen, X., Memon, H. A., Wang, Y., Marriam, I. & Tebyetekerwa, M. (2021). Circular Economy and sustainability of the clothing and textile Industry. *Materials Circular Economy*, 3 (1), 1-9.

Croxton, K. L., Lambert, D. M., García-Dastugue, S. J. & Rogers, D. S. (2002). The Demand Management Process. *The International Journal of Logistics Management*, 13 (2), 51-66.

Davenport, T. H. (2013). Analytics 3.0. *Harvard Business Review*, 91 (12) 64-72.

Delen, D. & Demirkan, H. (2013). Data, information and analytics as services. *Decision Support Systems*, 55 (1), 359-363.

Evans, J. (2015). Modern analytics and the future of quality and performance excellence. *The quality management journal*, 22 (4), 6-17.

Fisher, M. & Raman, A. (1996). Reducing the cost of demand uncertainty through accurate response to early sales. *Operations research*, 44 (1), 87-99.

Gandomi, A. & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35 (2), 137-144.

Gazzola, P., Pavione, E., Pezzetti, R. & Grechi, D. (2020). Trends in the Fashion Industry. The Perception of Sustainability and Circular Economy: A Gender/Generation Quantitative Approach. *Sustainability*, 12 (7).

- Giri, C., Thomassey, S. & Zeng, X. (2019). Exploitation of Social Network Data for Forecasting Garment Sales. *International Journal of Computational Intelligence Systems*, 12 (2), 1423-1435.
- Guo, Z. X., Wong, W. K., Leung, S. & Li, M. (2011). Applications of artificial intelligence in the apparel industry: a review. *Textile Research Journal*, 81 (18), 1871-1892.
- Hack-Polay, D., Rahman, M., Billah, M. M. & Al-Sabbahy, H. (2020). Big data analytics and sustainable textile manufacturing: Decision-making about the applications of biotechnologies in developing countries. *Management Decision*, 58 (8), 1699-1714.
- Inditex. (2020). Annual Report 2019. [Verkkodokumentti]. [Viitattu 8.11.2022]. Saatavilla: [https://static.inditex.com/annual\\_report\\_2019/pdfs/en/memoria/2019-Inditex-Annual-Report.pdf](https://static.inditex.com/annual_report_2019/pdfs/en/memoria/2019-Inditex-Annual-Report.pdf)
- Jin, X., Wah, B. W., Cheng, X. & Wang, Y. (2015). Significance and Challenges of Big Data Research. *Big Data Research*, 2 (2), 59-64.
- Kenneth, B. K. (2003). How to measure the impact of a forecast error on an enterprise? *The Journal of Business Forecasting*, 22 (1), 21-25.
- Kharfan, M., Chan, V. W. K. & Efendigil, T. F. (2020). A data-driven forecasting approach for newly launched seasonal products by leveraging machine-learning approaches. *Annals of Operations Research*, 303 (1-2), 159-174.
- Liew, A. (2007). Understanding Data, Information, Knowledge And Their Inter-Relationships. *Journal of Knowledge Management Practice*, 7 (2).
- Magnusdottir, A. (2020). How Fashion Manufacturing Will Change After the Coronavirus. [WWW-dokumentti]. [Viitattu 14.9.2022]. Saatavilla: <https://www.forbes.com/sites/aslaug-magnusdottir/2020/05/13/fashions-next-normal/?sh=30d39c578f38>

Mahmood, S. & Kess, P. (2016). An overview of demand management through demand supply chain in fashion industry. *International Journal of Management Science and Business Administration*, 2 (12), 7-19.

McAfee, A., Brynjolfsson, E., Davenport, T. H., Patil, D. J. & Barton, D. (2012). Big data: the management revolution. *Harvard Business Review*, 90 (10), 60-68.

Miller, H. G. & Mork, P. (2013). From Data to Decisions: A Value Chain for Big Data. *IT Professional*, 15 (1), 57-59.

Mukherjee, A., Panayotov, G. & Shon, J. (2021). Eye in the sky: Private satellites and government macro data. *Journal of Financial Economics*, 141 (1), 234-254.

Müller, S. D. & Jensen, P. (2017). Big data in the Danish industry: application and value creation. *Business Process Management Journal*, 23 (3), 645-670.

Nenni, M. E., Giustiniano, L. & Pirolo, L. (2013). Demand Forecasting in the Fashion Industry: A Review. *International Journal of Engineering Business Management*, 5.

Rajaraman, V. (2016). Big data analytics. *Resonance*, 21 (8), 695-716.

Raza, D. & Kilbourn, P. (2017). The impact of point-of-sale data in demand planning in the South African clothing retail industry. *Journal of Transport and Supply Chain Management*, 11 (1), 1-8.

Ren, S., Chan, H. & Siqin, T. (2019). Demand forecasting in retail operations for fashionable products: methods, practices, and real case study. *Annals of Operations Research*, 291 (1-2), 761-777.

Rexhausen, D., Pibernik, R. & Kaiser, G. (2012). Customer-facing supply chain practices—The impact of demand and distribution management on supply chain success. *Journal of Operations Management*, 30 (4), 269-281.

- Runkler, T. A. (2016). *Data Analytics Models and Algorithms for Intelligent Data Analysis*. 2nd ed. Wiesbaden: Springer Fachmedien Wiesbaden.
- See-To, E. & Ngai, E. W. T. (2018). Customer reviews for demand distribution and sales nowcasting: a big data approach. *Annals of Operations Research*, 270 (1-2), 415-431.
- Sen, A. (2008). The US fashion industry: A supply chain review. *International Journal of Production Economics*, 114 (2), 571-593.
- Shim, S., Kim, J. & Na, Y. (2018). An explanatory study on up-cycling as the sustainable clothing life at home. *Fashion and Textiles*, 5 (1), 1-15.
- Shirvanimoghaddam, K., Motamed, B., Ramakrishna, S. & Naebe, M. (2020). Death by waste: Fashion and textile circular economy case. *The Science of the Total Environment*, 718.
- Simon, R. (2008). The ABCs of point of sales (POS) data. *The Journal of Business Forecasting*, 27 (4).
- Smith, P. (2022). Global apparel market - statistics & facts. [WWW-dokumentti]. [Viitattu 24.9.2022]. Saatavilla: <https://www.statista.com/topics/5091/apparel-market-world-wide/#dossierKeyfigures>
- Souza, G. C. (2014). Supply chain analytics. *Business Horizons*, 57 (5), 595-605.
- Stieglitz, S., Mirbabaie, M., Ross, B. & Neuberger, C. (2018). Social media analytics—Challenges in topic discovery, data collection, and data preparation. *International Journal of Information Management*, 39, 156-168.
- Sull, D. & Turconi, S. (2008). Fast fashion lessons. *Business Strategy Review*, 19 (2), 4-11.

Suthamathi, D. & Jeeva, S. (2020). Online Shopping Vs Offline Shopping Customer Preference In Salem District. *International Journal of Scientific & Technology Research*, 9 (2), 5394-5398.

Thomassey, S. (2010). Sales forecasts in clothing industry: The key success factor of the supply chain management. *International Journal of Production Economics*, 128 (2), 470-480.

Vinodh, S., Arvind, K. R. & Somanaathan, M. (2011). Tools and techniques for enabling sustainability through lean initiatives. *Clean Technologies and Environmental Policy*, 13 (3), 469-479.

Zhang, C., Tian, Y.-X. & Fan, L.-W. (2020). Improving the Bass Model's Predictive Power through Online Reviews, Search Traffic and Macroeconomic Data. *Annals of Operations Research*, 295 (2), 881-922.