



**TURUN  
YLIOPISTO**  
Kauppakorkeakoulu

## **Ajoneuvojen varaosien kysynnän ennustaminen**

Toimitusketjujen johtaminen  
kandidaatintutkielma

Laatija:  
Esko Sipiläinen

Ohjaaja:  
TkT Riikka Kaipia

28.4.2024

Turku

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

Kandidutkielma

**Oppiaine:** Toimitusketjujen johtaminen

**Tekijä:** Esko Sipiläinen

**Otsikko:** Ajoneuvojen varaosien kysynnän ennustaminen

**Ohjaaja:** TkT Riikka Kaipia

**Sivumäärä:** 35 sivua

**Päivämäärä:** 28.4.2024

Varaosien saatavuudella on suuri vaikutus asennetun laitekannan tehokkaaseen käyttöön: ilman nopeaa varaosatoimitusta laiteseisokit pitenevät, ja kerrannaisvaikutukset voivat olla suuria. Kriittisten osien toimitusvaikeudet saattavat esimerkiksi pysäyttää kokonaisia tuotantolaitoksia tai lamauttaa kuljetuksia. Varaosavarastoinnin tarkoituksena on minimoida laiteseisokkeja varmistamalla tarvittavien osien saatavuus. Haasteena on löytää oikea tasapaino varaosien saatavuuden ja niiden varastointikustannusten välillä. Kysynnän ennustamisella on iso merkitys tehokkaalle varastonhallinnalle sekä siitä aiheutuvien kustannusten hallinnalle.

Tämän kandidaatintutkielman tavoitteena on tutkia, miten ajoneuvojen varaosien kysyntää voidaan ennustaa. Tutkielma tarkastelee kysynnän ennustamisen menetelmiä, ajoneuvojen varaosien erityispiirteitä, niiden ennustamisen haasteita ja niiden ennustamiseen kehitettyjä menetelmiä. Tutkielma on toteutettu kirjallisuuskatsauksena.

Tutkielma jakautuu kolmeen pääosaan. Ensimmäisessä osassa käsitellään kysynnän ennustamisen teoriaa ja esitellään yleisiä kvalitatiivisia ja kvantitatiivisia ennustemenetelmiä. Toisessa osassa tarkastellaan ajoneuvojen varaosien kysynnän ennustamisen haasteita keskittyen tutkielman kannalta merkityksellisiin näkökulmiin. Kolmannessa osassa esitellään varaosien kysynnän ennustamiseen kehitettyjä ja siihen soveltuvia ennustemenetelmiä. Näistä menetelmistä keskitytään epäsäännöllisen kysynnän parametrisiin menetelmiin, WSS-menetelmään ja asennetun laitekannan tietoa hyödyntäviin menetelmiin.

Tutkielmassa havaittiin, että ajoneuvojen varaosien kysynnän ennustamisen haasteena on epäsäännölliset kysyntäkuviot, varaosien vanhentuminen ja niiden suuri lukumäärä sekä varaosien kysynnän luonne. Tutkielman perusteella voidaan todeta varaosien kysynnän ennustamiseen suunniteltujen ennustemenetelmien antavan tarkempia tuloksia kuin yksinkertaiset aikasarjamenetelmät. Tämän lisäksi myös asennetun laitekannan tietojen hyödyntämisestä varaosien ennustamisessa on selvää näyttöä etenkin laitekannan koon vaihdellessa. Kuitenkin empiirinen näyttö eri varaosien ennustamismenetelmien keskinäisestä suorituskyvystä on vaihtelevaa, ja lisää empiiristä tutkimusta aiheesta tarvitaan. Tämän lisäksi tutkielman perusteella ennustamismenetelmän valinnassa on punnittava ennustetarkkuutta ja ennustamisen edellyttämää tietotaitoa ja kustannuksia.

**Avainsanat:** varaosat, ajoneuvojen varaosat, varaosien kysynnän ennustaminen, kysynnän ennustaminen, kysynnän ennustamismenetelmät

# SISÄLLYS

<b>1</b>	<b>Johdanto</b>	<b>7</b>
1.1	Tutkielman tavoitteet, rajaukset ja menetelmä	7
1.2	Tutkielman rakenne	8
<b>2</b>	<b>Kysynnän ennustaminen</b>	<b>9</b>
2.1	Kysynnän ennustaminen	9
2.2	Kvantitatiiviset ennustamismenetelmät	9
2.2.1	Naiivimenetelmä	11
2.2.2	Liukuva keskiarvo	11
2.2.3	Eksponentiaalinen tasoitus	12
2.3	Kvalitatiiviset ennustamismenetelmät	12
2.3.1	Delphi-menetelmä	13
2.3.2	Sales force composite	14
2.4	Menetelmien ja ennusteiden yhdistäminen	14
<b>3</b>	<b>Varaosat ja ennustamisen haasteet</b>	<b>16</b>
3.1	Kysyntäkuviot	16
3.2	Vanhentuminen ja varaosien suuri lukumäärä	18
3.3	Varaosien kysyntään vaikuttavat tekijät	20
3.3.1	Ajoneuvoon liittyvät tekijät	20
3.3.2	Varaosaan liittyvät tekijät	21
3.3.3	Huoltoon liittyvät tekijät	22
3.3.4	Varaosamarkkinoihin liittyvät tekijät	22
<b>4</b>	<b>Ratkaisuja</b>	<b>23</b>
4.1	Epäsäännöllisen kysynnän menetelmät	23
4.2	Bootstrapping-menetelmät	26
4.3	Asennetun laitekannan tieto	28
<b>5</b>	<b>Yhteenveto ja johtopäätökset</b>	<b>30</b>
	Lähteet	32

## **KUVIOT**

Kuva 1 Aikasarjamalli ja sen piirteitä (mukaillen Mentzer & Moon 2005, 75)	10
Kuva 2 Ennustemallin valinta (mukaillen Syntetos ym. 2005)	17
Kuva 3 Varaosien elinkaarimalli (mukaillen Klug 2018, 498)	18
Kuva 4 WSS-menetelmän vaiheet (mukaillen Willemain ym. 2004; Hasni ym. 2019b)	27



# 1 Johdanto

Uudessa henkilöautossa on keskimäärin noin 30 000 eri osaa. Osat kuluvat ja rikkoutuvat, jolloin niitä vaihdetaan uusiin. Varaosia tulee tällöin olla nopeasti saatavilla ripeän huolto- ja korjaustoiminnon varmistamiseksi. Osien saatavuusongelmat saattavat vaarantaa ajoneuvon käytön ja aiheuttaa ylimääräisiä kustannuksia. Varaosien saatavuuden varmistamiseksi valmistajat ja jälleenmyyjät pitävät suuria varastopuskureita. Ylimääräisen varaston pitäminen voi kuitenkin tulla kalliiksi, jos varastointi koskee suurta määrää osia tai kalliita osia. (Van der Auerwarer & Boyte 2019.)

Markkinatutkimuksen mukaan varaosien hintojen arvioidaan nousevan niiden kasvavan kompleksisuuden ja uuden teknologian käyttöönoton seurauksena. Ajoneuvojen sähköistyminen myös muuttaa niiden varaosatarpeita. Saman tutkimuksen mukaan autojen varaosamarkkinoiden arvioidaan kasvavan hitaasti ja kilpailun kiristyvän vuoteen 2030 mennessä. (Waas ym. 2021.) Klugin (2018, 497) mukaan myynninjälkeisillä palveluilla kuten varaosilla ja huolloilla voidaan luoda asiakasuskollisuutta ja samalla varaosaliiketoiminnalla on merkittävä osuus alan yritysten myynnissä ja voiton tuotossa. Näin ollen varaosaliiketoiminta on merkittävä osa ajoneuvoteollisuutta.

Varaosien kysynnän tarkka ennustaminen on tärkeää tehokkaalle varastohallinnalle ja sen kustannusten hallitsemiselle (Klug 2018, 504). Tarkalla ennusteella voidaan vähentää esimerkiksi varastoinnista, vanhentumisesta ja logistiikasta aiheutuvia kustannuksia, ja siten vastata kiristyvään kilpailuun. Varaosien kysynnän ennustaminen on kuitenkin haastavaa.

Tässä kandidaatintutkielmassa käsitellään ajoneuvojen varaosien kysynnän ennustamisen menetelmiä. Tutkielmassa tarkastellaan kirjallisuuteen perustuen kysynnän ennustamista ja ennustemenetelmiä, ajoneuvojen varaosien kysyntää, sekä varaosien kysynnän ennustamiseen soveltuvia menetelmiä.

## 1.1 Tutkielman tavoitteet, rajaukset ja menetelmä

Tutkielman tavoitteena on avata kysynnän ennustamisen menetelmiä ja niiden käyttöä ajoneuvojen varaosien kysynnän ennustamisessa. Tarkoituksena on tarkastella kysynnän ennustamisen ja siinä käytettäviä eri menetelmiä ajoneuvojen varaosien näkökulmasta.

Tutkielman tutkimuskysymys ja alatutkimuskysymykset ovat seuraavat:

- Miten ajoneuvojen varaosien kysyntää voidaan ennustaa?
  - Mitä kysynnän ennustaminen on?
  - Mitkä ovat ajoneuvojen varaosien erityispiirteet ja mitä haasteita niillä on kysynnän ennustamisen kannalta?
  - Mitä menetelmiä ajoneuvojen varaosien kysynnän ennustamiseksi on kehitetty?

Tutkielma on toteutettu kirjallisuuskatsauksena. Tutkielman lähteinä on pääosin käytetty vertaisarvioituja artikkeleita sekä alan oppikirjoja.

## 1.2 Tutkielman rakenne

Tutkielma koostuu johdannosta, kolmesta varsinaisesta sisältöluvusta sekä yhteenvedosta ja johtopäätöksistä. Ensimmäisessä sisältöluvussa eli luvussa kaksi esitellään kysynnän ennustamista ja vastataan ensimmäiseen alatutkimuskysymykseen. Luvussa esitellään kysynnän ennustaminen yleisesti ja siinä usein käytettyjä menetelmiä lyhyesti.

Luvussa kolme käsitellään varaosien erityispiirteet ja niiden ennustamiseen liittyvät haasteet ja vastataan toiseen alatutkimuskysymykseen. Luvussa esitellään kirjallisuuden pohjalta varaosien kysynnän ennustamiseen liittyvät keskeiset haasteet kuten epäsäännölliset kysyntäkuviot, vanhentuminen ja varaosien kysynnän erityispiirteet.

Luvussa neljä esitellään kirjallisuudessa esitettyjä varaosien kysynnän ennustamiseen tarkoitettuja ja siihen soveltuvia ennustamismenetelmiä ja vastataan kolmanteen alatutkimuskysymykseen. Luvussa esitellään eri aikasarjamenetelmiä ja muita tilastollisia menetelmiä sekä asennetun laitekannan tietoa hyödyntäviä malleja.

Viides ja viimeinen luku kiteyttää koko tutkielman ja esittää tutkielman keskeiset johtopäätökset ja muut huomionarvoiset asiat. Luvussa pohditaan esitettyjen menetelmien vahvuuksia ja heikkouksia sekä jatkotutkimuksen tarvetta.



## 2 Kysynnän ennustaminen

### 2.1 Kysynnän ennustaminen

Ennustaminen on keskeisessä asemassa liiketoiminnassa, koska lähes kaikki yrityksen päätökset perustuvat niihin (Kolassa & Siemensen 2016). Babain ym. (2022) mukaan toimitusketjujen hallinnan osalta ennusteita tarvitaan useimpien päätöksien tueksi. Heidän mukaansa kysyntää tyypillisesti ennustetaan eri ajanjaksoille ja eri tuotetarkkuuksille, yksittäisestä varastointiyksiköstä kaikkiin tuotteisiin. Tämän lisäksi on myös mahdollista huomioida muita ulottuvuuksia kuten maantieteellinen sijainti.

On tärkeää erottaa ennusteet suunnitelmista tai tavoitteista. Ennusteet ovat tietoon perustuvia arvioita tulevasta kysynnästä. Ennusteprosessin ensisijainen tavoite on aina tarkkuus, eli luoda arvio tulevasta kysynnästä, joka on mahdollisimman lähellä todellisuutta. (Moon 2018, 65–66). Suunnitelmat ovat sen sijaan yrityksen itselleen asettamia suuntia, jotka toteuttamalla aiotaan saavuttaa asetetut tavoitteet. Suunnitelmat ja tavoitteet täten perustuvat usein ennusteisiin.

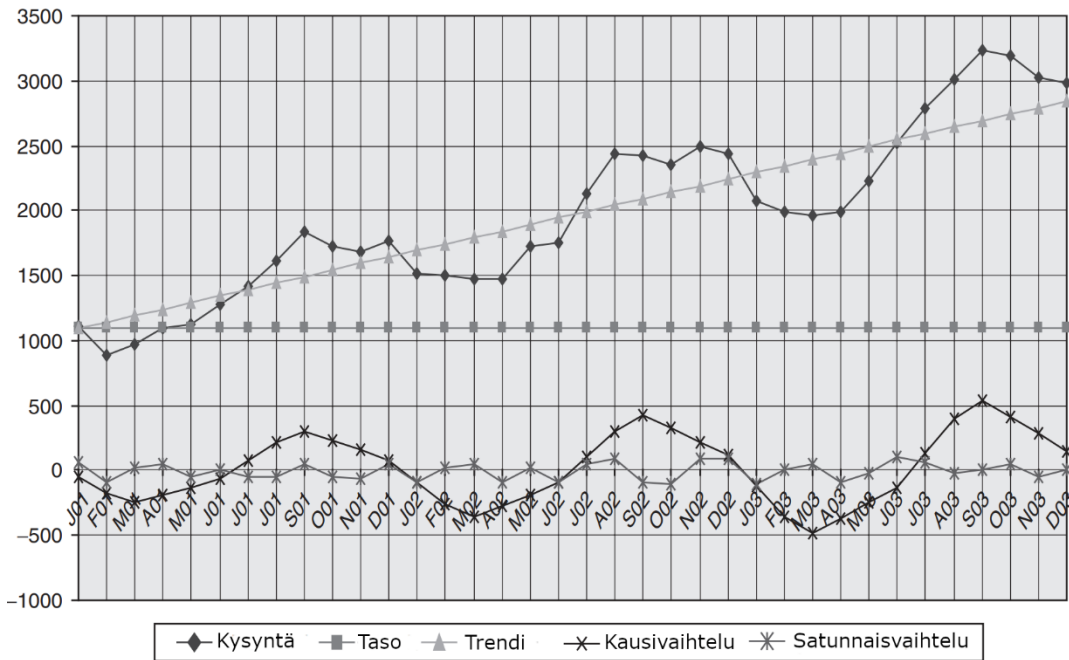
Moon (2018, 67) määrittelee kysynnän tarkoittavan sitä, mitä asiakkaat ostaisivat, jos heille annettaisiin siihen mahdollisuus, ja korostaa tarkan ennustamisen merkitystä asiakkaiden odotusten täyttämässä ja resurssien kohdentamisessa. Kysynnän ennustaminen on näin ollen tehokkaan päätöksenteon perusta, jonka avulla yritykset pystyvät selviytymään epävarmuustekijöistä ja parantamaan toiminnan tehokkuutta.

Kirjallisuudessa ennustamismenetelmät jaetaan kahteen pääryhmään: kvalitatiivisiin ja kvantitatiivisiin menetelmiin. Seuraavissa luvuissa esitellään näitä menetelmiä tarkemmin.

### 2.2 Kvantitatiiviset ennustamismenetelmät

Kvantitatiiviset ennustamismenetelmät perustuvat historialliseen tietoon. Hyndmanin ja Athanasopouloksen (2018, 12) mukaan kvantitatiivisia menetelmiä voidaan käyttää, kun numeerista historiallista tietoa on saatavilla ja on kohtuullista olettaa, että jotkin menneisyyden piirteet jatkuvat myös tulevaisuudessa. Moonin (2018, 88) mukaan kvantitatiivisen ennustamisen perusajatuksena on löytää ja dokumentoida kysynnän piirteitä. Käytännössä tällöin tieto on tilastoitavissa ja sen pohjalta voidaan tehdä ennusteita tulevaisuudesta.

Kvantitatiiviset ennustamismenetelmät voidaan jakaa kahteen pääryhmään: aikasarjamenetelmiin ja kausaalimenetelmiin. Moonin (2018, 88) mukaan aikasarjamenetelmät pyrkivät tunnistamaan historiallisessa datassa ajan myötä toistuvia piirteitä, kuten trendejä, kausivaihteluita ja satunnaisvaihteluita. Alla olevassa kuviossa on esimerkki aikasarjasta ja sen toistuvista piirteistä. Aikasarjamenetelmiä on lukuisia yksinkertaisimmasta naiivimenetelmästä monimutkaisiin algoritmeihin.



Kuva 1 Aikasarjamalli ja sen piirteitä (mukaillen Mentzer & Moon 2005, 75)

Kausaalimallien käyttö perustuu ajatukseen, jossa kysyntä on riippuvainen myös muista tekijöistä. Moonin (2018, 106) mukaan regressioanalyysi on yksi yleisemmin käytetyistä ennustetyökaluista aikasarjamenetelmien lisäksi. Regressiomallilla voisi esimerkiksi tutkia miten hiekoitushiekan kysyntään vaikuttaa lämpötilanvaihtelut tai miten tuotteen hinta vaikuttaa sen kysyntään.

Moonin (2018, 112) mukaan kvantitatiiviset ennustamismenetelmät ovat erinomainen tapa aloittaa ennustaminen. Hänen mukaansa historiallisen kysynnän ymmärtäminen voi olla hyödyllistä, riippumatta piirteiden toistuvuudesta tai muiden tekijöiden vaikutuksesta. Seuraavissa alaluvuissa esitellään lyhyesti joitain yksinkertaisia aikasarjamenetelmiä.

### 2.2.1 Naiivimenetelmä

Naiivimenetelmä on yksinkertaisin aikasarjaennustemenetelmä. Moonin (2018, 91) mukaan naiivimenetelmässä tulevan ajanjakson ennusteeksi asetetaan toteutunut kysyntä viimeisellä ajanjaksolla. Ennustettaessa tällöin kysyntää esimerkiksi huhtikuulle, asetettaisiin ennusteeksi maaliskuun toteutunut kysyntä. Ennuste ei tällöin ota historiallisessa kysynnässä mahdollisesti esiintyvää trendiä, kausivaihteluita tai satunnaisvaihteluita lainkaan huomioon (Moon 2018, 91). Mikäli jaksojen välillä on merkittävää vaihtelua, niin ennuste seuraa tätä vaihtelua myöhässä.

Naiivimenetelmä voidaan esittää matemaattisesti seuraavasti:

$$Y_{t+1} = X_t$$

missä

$$Y_{t+1} = \text{ennuste ajanjaksolle } t + 1$$

$$X_t = \text{toteutunut kysyntä ajanjaksolla } t$$

### 2.2.2 Liukuva keskiarvo

Liukuvaa keskiarvoa voidaan hyödyntää ennustamisessa. Liukuvassa keskiarvossa ennuste lasketaan useamman jakson keskiarvona, jolloin naiivimenetelmässä esiintyvä vaihtelu vähentyy. Ennustettaessa on kuitenkin tehtävä päätös, siitä kuinka monesta ajanjaksosta keskiarvo lasketaan. (Moon 2018, 95–98). Valittujen ajanjaksojen määrällä on myös vaikutusta mallin kykyyn mukautua historiallisessa datassa mahdollisesta olevaan trendiin ja kausivaihteluun. Moon (2018, 97) mukaan esimerkiksi pitkän ajanjakson liukuva keskiarvo ei kykene huomiomaan kausivaihteluita riittävällä tasolla. Täten liukuva keskiarvo ei sovellu kausivaihtelevan kysynnän ennustamiseen erityisen hyvin.

Malli voidaan esittää matemaattisesti seuraavasti:

$$Y_{t+1} = \frac{X_t + X_{t-1} + X_{t-2} + \dots + X_{t-[N-1]}}{N}$$

missä

$$Y_{t+1} = \text{ennuste ajanjaksolle } t + 1$$

$X_t$  = toteutunut kysyntä ajanjaksolla  $t$

$N$  = ajanjaksojen lukumäärä (Mukaiillen Moon 2018, 95)

### 2.2.3 Eksponentiaalinen tasoitus

Eksponentiaalinen tasoitus perustuu tietyn painoarvon antamiselle tuoreimmille havainnoille, jolloin niitä painotetaan enemmän kuin vanhempia. Täten menetelmä eroaa liukuvasta keskiarvosta, jossa kaikilla mukana olevilla ajanjaksoilla on sama painoarvo. Hyndmanin ja Athanasopouloksen (2018, 237) mukaan eksponentiaalisen tasoituksen sovellukset tuottavat luotettavia ennusteita nopeasti monenlaisista aikasarjoista. Tässä luvussa keskitytään yksinkertaiseen eksponentiaaliseen tasoitukseen (SES, Simple Exponential Smoothing).

Malli voidaan esittää matemaattisesti:

$$Y_{t+1} = \alpha X_t + \alpha(1 - \alpha)X_{t-1} + \alpha(1 - \alpha)^2 X_{t-2} + \dots$$

missä

$Y_{t+1}$  = ennuste ajanjaksolle  $t + 1$

$X_t$  = toteutunut kysyntä ajanjaksolla  $t$

$\alpha$  = painokerroin välillä  $[0,1]$  (Mukaiillen Hyndman & Athanasopoulos 2018, 240)

Moonin (2018, 99–100) mukaan eksponentiaalinen tasoitus korjaa joitain liukuvan keskiarvon haasteista, koska uusien tapahtumien painoarvoa voidaan säätää vapaasti, jolloin mallia voi säätää dataan sopivaksi. Äärimmäisessä tilanteessa, jossa painokertoimen arvo on yksi ovat ennusteet naiiveja. Tämän yksinkertainen mallin lisäksi on kehitetty eksponentiaalisen tasoituksen malleja, jotka huomioivat kausivaihteluita ja trendejä (ks. Holt 2004; Winters 1960).

## 2.3 Kvalitatiiviset ennustamismenetelmät

Kvalitatiiviset eli laadulliset ennustemallit perustuvat ennustettavaan asiaan perehtyneiden henkilöiden tietoihin, mielipiteisiin ja intuitioihin. Kvalitatiivisia malleja käytetään usein silloin kun historiadataa ei ole saatavilla tai se on heikkolaatuista, tai epäillään tulevaisuuden poikkeavan historiasta merkittävästi. (Moon 2018, 113).

Sandersin ym. (2017, 52) mukaan kvalitatiivisten menetelmien vahvuuksina ovat yllä olevien lisäksi niiden kyky reagoida nopeasti muutoksiin ja kyky sisällyttää tietoa, jota ei voida helposti kvantifioida. Tällaisia tilanteita voivat olla esimerkiksi uusien tuotteiden tuominen markkinoille tai uuden kilpailijan muuttama kilpailutilanne. Kvalitatiivisilla menetelmillä on kuitenkin heikkouksia, jotka Sandersin ym. (2017, 52) mukaan liittyvät ihmisen kognitiivisiin rajoihin ja ennakoasenteisiin. Ihmiset saattavat esimerkiksi olla liian optimistisia tulevaisuuden suhteen tai ns. ankkuroitua alkuperäisiin tietoihin, jolloin ennusteet saattavat perustua liikaa vanhoihin tietoihin uudempien sijaan.

Heikkouksista huolimatta kvalitatiiviset menetelmät ovat Sandersin ym. (2017, 53) mukaan käytetympiä ennustemenetelmiä yrityksissä, koska ne ovat yksinkertaisempia ja helpompia ymmärtää ja täten tuntuvat luotettavammalta kuin kvantitatiiviset menetelmät. Seuraavissa esitellään lyhyesti joitain tunnetuimmista kvalitatiivisista ennustemenetelmistä.

### 2.3.1 Delphi-menetelmä

Delphi-menetelmä kehitettiin 1950-luvulla asiantuntijalausuntojen soveltamiseksi yhdysvaltalaisessa RAND-tutkimuslaitoksessa. Menetelmän alkuperäisenä tarkoituksena oli selvittää ydinaseiden vaikutusta Neuvostoliiton sodankäynnin strategiaan. (Dalkey & Helmer 1963.) Delphi-menetelmä perustuu oletukseen, että ryhmän tuottamat ennusteet ovat tarkempia kuin yksilön. Menetelmän tavoitteena on laatia yksimielinen ennuste jäsennellyllä ja iteratiivisen prosessin avulla ryhmältä asiantuntijoita. Käytännössä menetelmässä valitaan osallistujat, joille annetaan ennustetehtävät joihin he vastaavat. Vastaukset kootaan yhteen ja palautetaan, jonka jälkeen osallistujat arvioivat ennusteensa uudelleen. Tätä vaihetta voidaan toistaa uudelleen tarpeen mukaan. Lopulliset ennusteet muodostetaan yhdistämällä asiantuntijoiden ennusteet. (Hyndman & Athanasopoulos 2018, 111.)

Moonin (2018, 124–125) mukaan Delphi-menetelmä vähentää ryhmätyöskentelyn mahdollisia ongelmia, koska asiantuntijat eivät kohtaa toisiaan. Tällöin esimerkiksi henkilökohtaiset suhteet tai esimiesasema eivät vaikuta ennusteiden arvioimiseen, jolloin erilaisiakin ennusteita arvioidaan samalla tavalla. Hänen mukaansa tämän seurauksena menetelmästä voi nousta erilaisia skenaarioita ja lopputulos on oikeutetumpi. Menetelmään kuitenkin liittyy haasteita.

Hyndmanin ja Athanasopouloksen (2018, 113) ja Moonin (2018, 125) mukaan menetelmän käyttäminen vie paljon aikaa ja menetelmällä saadut tulokset ovat riippuvaisia käytetystä asiantuntijapaneelistä. Tämän takia menetelmän käyttäminen on Moonin (2018, 125) mukaan järkevintä pitkän ajanjakson strategisiin ennusteisiin operatiivisten sijaan.

### 2.3.2 Sales force composite

Sales force composite -menetelmässä hyödynnetään yrityksen myynissä työskentelevien ihmisten tietoa ja kokemusta kysyntäennusteiden tuottamiseksi tai niiden muokkaamiseksi. Menetelmä on erityisen hyödyllinen silloin kun myyjät hallinnoivat tuotevirtoja asiakkaille ja projektiluontoisessa liiketoiminnassa, jossa myyjät voivat paremmin arvioida uusien projektien toteutumisen todennäköisyyttä. (Moon 2018, 125.)

Hyndmanin ja Athanasopouloksen (2018, 118) mukaan tähän menetelmään liittyy ongelmia. Heidän mukaansa myyjien tuottamiin ennusteet saattavat olla heikkoja johtuen mm. mahdollisista vinoumista ja koulutuksen puutteesta. Esimerkiksi ennusteen ylittävään myyntiin perustuva palkkiomalli saattaa johtaa tarkoituksella alakanttiin oleviin ennusteisiin. Moonin (2018, 127–130) mukaan näiden ennusteiden parantamiseksi tarvitaan koulutusta ja ennustamisen tulee olla riittävän yksinkertaista ja helppoa. Käytännössä myyjä voisi esimerkiksi muuttaa olemassa olevaa ennustetta havaitsemiensa muutoksien mukaisesti.

## 2.4 Menetelmien ja ennusteiden yhdistäminen

Moonin (2018, 83) mukaan kuitenkin useimmissa tilanteissa kumpikaan näistä pääryhmistä ei yksinään riitä erinomaisen ennusteen laatimiseen. Hänen mukaansa huippuennusteiden laatiminen edellyttää näiden menetelmien yhdistämistä.

Kvantitatiivisten ja kvalitatiivisten ennustemenetelmien yhdistämiseksi on esitetty eri tapoja:

- **Muokkaava (Judgemental adjustment):** Kvalitatiivisella menetelmällä muokataan kvantitatiivisen menetelmän antamaa ennustetta. Esimerkiksi aikasarjamenetelmän ennustetta muokataan suuremmaksi tulevan kampanjan takia.

- Korjaava (Quantitative correction): Kvantitatiivista menetelmää käytetään kvalitatiivisen ennusteen korjaamiseen. Esimerkiksi regressiota voidaan käyttää virheiden ennustamiseksi ja kvalitatiivisen ennusteen korjaamiseksi.
- Yhdistävä (combining): Ennuste saadaan yhdistämällä kvalitatiivinen ja kvantitatiivinen ennuste jollain painoarvolla.
- Osa mallinrakennusta (Judgement as input to model building): kvalitatiivisia menetelmiä käytetään mallin muuttujien valinnassa ja parametrien arvojen asettamisessa. (Sanders & Ritzman 2004.)

Menetelmien ja eri ennusteiden yhdistämistä on tutkittu kirjallisuudessa jo kauan aiemmin. Clemen (1989) mukaan ennusteiden tarkkuutta voidaan parantaa huomattavasti yhdistämällä yksittäisiä ennusteita verrattuna monimutkaisiin malleihin. Hänen mukaansa yksinkertaiset yhdistelmämenetelmät toimivat usein kohtuullisen hyvin verrattuna monimutkaisempiin tilastollisiin malleihin. Atiyan (2020) mukaan ennusteiden yhdistämisen taustalla on ajatus siitä, että ennustettavilla asioilla kuten kysynnällä on tyypillisesti lyhyt tai muuten rajallinen historia, jonka pohjalta ei ole käytännössä mahdollista määritellä ennustettavaa asian taustalla olevaa prosessia. Yksittäisen ennustemallin epätarkkuuden vähentämiseksi on täten järkevää yhdistää useiden eri ennustemallien tuottamia ennusteita, jolloin ennusteen epätarkkuus pienenee.

### 3 Varaosat ja ennustamisen haasteet

Kennedyn ym. (2002) mukaan varaosat eroavat merkittävästi muista hyödykkeistä, koska niitä käytetään osana huoltotoimenpiteitä muiden laitteiden tai tuotteiden toimintakunnon ylläpitämiseksi. Van der Auweraer ym. (2019) selventää, että varaosilla ei täten ole lopputuotteiden kaltaista itsenäistä kysyntää, mutta ei myöskään suoraan valmistettavista tuotteista riippuvaa kysyntää kuten valmistuksessa käytettävillä osilla. Näiden pohjalta voidaan sanoa, että varaosien kysyntä on pohjimmaltaan riippuvainen myytyjen lopputuotteiden huoltotarpeista.

Rezapourin ym. (2016) mukaan varaosien ja muiden myynnin jälkeisten palveluiden käyttö keskittyy erityisesti investointitavaroihin ja kestokulutushyödykkeisiin. Näille tuoteryhmille tyypillistä on tavaroiden pitkä käyttöikä ja ei-vähäinen taloudellinen arvo.

Ensimmäisenä mainituilla investointihyödykkeillä tarkoitetaan merkittäviä pitkäaikaisia taloudellisia investointeja, joita yritykset käyttävät muiden tavaroiden tai palveluiden tuottamiseen. Näiden hyödykkeiden toimintakatkokset voivat johtaa huomattaviin tappioihin, ja tyypillisesti tappiot kasvavat sitä suuremmaksi mitä pidempään katkos kestää. (Rezapour ym. 2016). Tämä asettaa merkittäviä vaatimuksia varaosien saatavuudelle ja koko varaosien toimitusketjulle. Investointihyödykkeisiin tyypillisesti luetaan mm. rakennukset, koneet, laitteet ja ajoneuvot. Toiseksi mainituilla kestokulutushyödykkeillä tarkoitetaan yksittäisten kuluttajien omaan käyttöönsä ostamia hyödykkeitä, kuten esimerkiksi autoja, kodinkoneita ja elektroniikkaa.

Kirjallisuudessa on esitetty useita tämän tutkimuksen aiheena olevan varaosien kysynnän ennustamiseen liittyviä haasteita: (1) varaosien epäsäännölliset tai satunnaiset kysyntäkuviot (Syntetos ym. 2005; Boylan & Syntetos 2010), (2) riski varaosien vanhentumisesta ja niiden suuri lukumäärä (Cohen ym. 2006) sekä (3) varaosien kysyntään vaikuttavat tekijät (Kennedy ym. 2002; Loukmidis & Luczak 2006).

Seuraavissa alaluvuissa käsitellään näitä ongelmia ja niihin esitettyjä ratkaisuja tarkemmin ajoneuvojen varaosien kannalta.

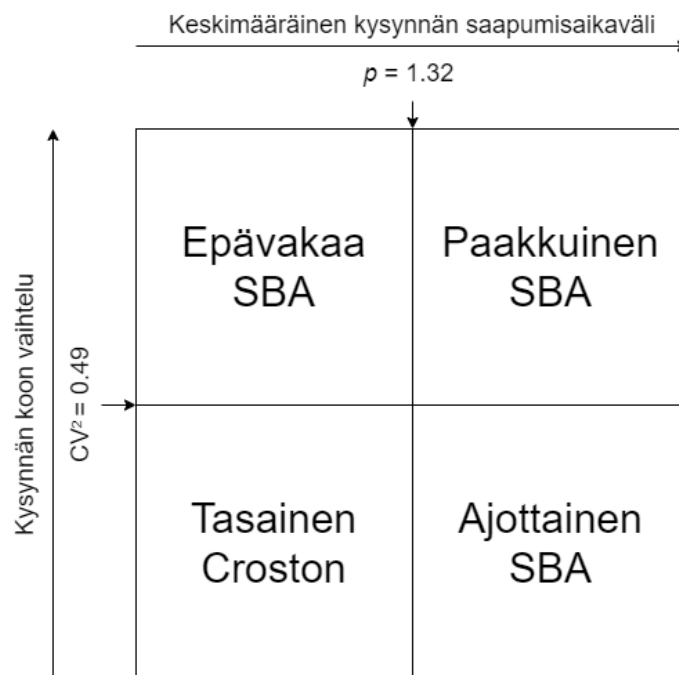
#### 3.1 Kysyntäkuviot

Van der Auweraerin ym. (2019) mukaan varaosien kysyntäkuviot usein poikkeavat huomattavista monien muiden tuotteiden kysyntäkuvioista. Vaikka joidenkin varaosien



kysyntä on suurta ja/tai vakaata, suurimmalla osalla kysyntä on epäsäännöllistä. Boylanin ja Syntetosin (2010) mukaan varaosien kysyntäkuviolle ominaista on nollakysyntähavaintojen sarja, jonka välissä on satunnaisia nolosta poikkeavia kysyntähavaintoja. Tämän lisäksi kysyntä voi esiintyessään olla usein hyvin vaihtelevan kokoista, joka tekee ennustamisesta hankalaa. Heidän mukaansa perinteisten parametrusten ennustemenetelmien on jo pitkään osoitettu yliarvioivan ajoittaisen kysynnän keskimääräistä tasoa, jos niitä sovelletaan välittömästi kysyntäpiikin jälkeen. Van der Auweraer ym. (2019) selventää, että kysynnän epäsäännöllisyys ja koon vaihtelevuus johtavat kysynnän koon vinoon jakaumaan, jolloin perinteisten mallien oletus normaalijakaumaoletus ei pidä. Tämän vuoksi on kehitetty erityisiä ennustemenetelmiä ajoittaista kysyntää varten.

Ennustetekniikan valitsemista varten on hyödyllistä luokitella tuotteet niiden kysyntäkuvioiden perusteella. Epäsäännöllisen kysynnän tapauksessa luokitteluun voidaan hyödyntää variaatiokertoimen neliötä, jolloin aikasarjan suuri hajonta korostuu. Syntetosin ym. (2005) mukaan variaatiokertoimelle  $CV^2$  ja keskimääräiselle kysynnän saapumisaikavälille  $p$  voidaan määrittää raja-arvot, joiden avulla tarkimman tuloksen antama ennustemalli voidaan valita. Alla olevassa kuviossa on esitetty ennustemallin valinta kysynnän hajonnan ja esiintymisen avulla.



Kuva 2 Ennustemallin valinta (mukaillen Syntetos ym. 2005)

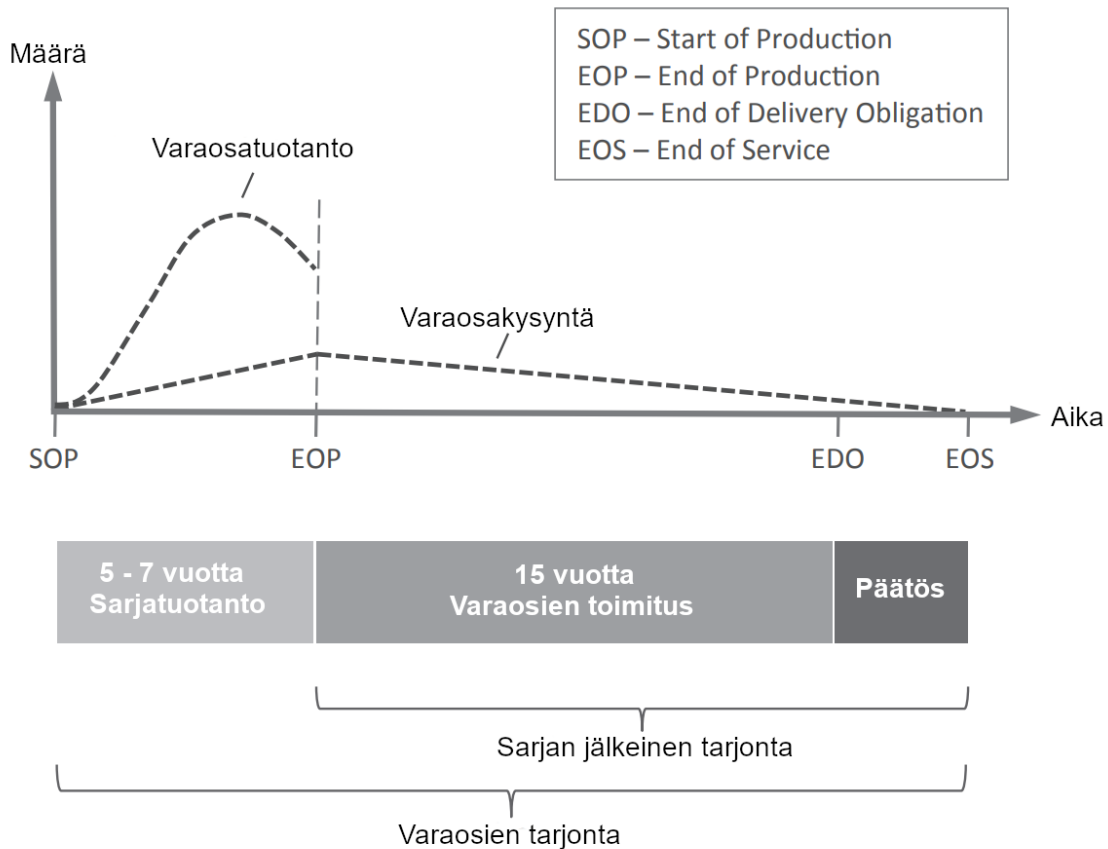
Epäsäännöllisen kysynnän ennustemalleja käsitellään tarkemmin luvussa 4.1.

### 3.2 Vanhentuminen ja varaosien suuri lukumäärä

Cohenin ym. (2006) mukaan 23 prosenttia varaosista vanhentuu vuosittain.

Vanhentumisella tässä yhteydessä tarkoitetaan varastoa jota ei ole myyty tai käytetty pitkään aikaan, eikä sitä odoteta myytävän tulevaisuudessa.

Kennedyn ym. (2002) mukaan vanhentuminen voi olla merkittävä ongelma, koska koneet joita varten varaosat ovat suunniteltu vanhenevat ja lopulta korvataan uusilla. Heidän mukaansa on vaikeaa määrittellä, kuinka paljon varaosia jo vanhentuneisiin laitteisiin on varastoiva. Laitteiden ja koneiden huoltokäytännöistä johtuen harvoin tarvittavien osien vanhentuminen on todennäköisempää, kuin toistuvassa huoltoiminnassa käytettävien osien. Varaosien vanhentumisriski on nostettu esille myös tuoreemmissa tutkimuksissa (ks. Zhang ym. 2021). Van der Auweraerin ym. (2019) mukaan vaikka ne koneet ja laitteet, joita varten osat ovat suunniteltu poistuisivat markkinoilta, asiakkaat edelleen voivat käyttää tuotetta ja täten luoda kysyntää varaosille. Tämä on ilmiselvää autojen osalla, joiden osalta varaosien elinkaarimalli on esitetty alla olevassa kuviossa.



Kuva 3 Varaosien elinkaarimalli (mukaiillen Klug 2018, 498)

- Tuotannon alkaminen (SOP): Ajoneuvon valmistus alkaa.
- Tuotannon päättyminen (EOP): Ajoneuvon sarjavalmistus lakkaa.
- Varaosien toimitusvelvollisuus päättyminen (EDO): Takuu ja sopimusvelvoitteet päättyvät
- Valmistajan huoltotoimintojen päättyminen (EOS): Alkuperäinen valmistaja (OEM) lopettaa ajoneuvon huoltotoimenpiteiden ja varaosien tarjoamisen.

Elinkaarimallista Klug (2018) erottaa kolme pääasiallista elinkaaren vaihetta.

Ensimmäinen vaihe alkaa uuden ajoneuvon tulosta markkinoille (SOP) ja se päättyy muutama vuosi sen jälkeen. Tässä vaiheessa Klugin (2018) mukaan varaosien kysynnän ennustaminen on vaikeaa, koska historiallista dataa varaosien hajoamisesta ja kysynnästä ei vielä ole. Tästä huolimatta varaosavarastojen tasot pidetään aluksi korkeana, jotta mahdolliset alkuvaiheen viat voidaan korjata mahdollisimman nopeasti.

Toinen vaihe alkaa muutama vuosi sarjatuotannon aloittamisen jälkeen ja päättyy tuotannon päättymiseen (EOP). Tälle vaiheelle on Klugin (2018) mukaan ominaista suhteellisen vakaa ajoneuvokanta. Valmistaja on tällöin saanut jo tietoa varaosien kestosta ja niiden kysynnästä. Klugin (2018) mukaan autojen monimutkaisesta rakenteesta, lyhenevistä tuotesykleistä ja varaosien pitkästä takuuajasta ja vikaantumisen satunnaisuudesta johtuen varaosien kysyntä vaihtelee ja niiden määrät ovat yleensä pienempiä. Tämän takia kysynnän ennustaminen tässä vaiheessa on hankalaa, mutta tarkempaa kuin ensimmäisessä vaiheessa.

Kolmas vaihe alkaa tuotannon päättymisestä (EOP) ja loppuu huoltotoimintojen päättymiseen (EOS). Kolmannelle vaiheelle on Klugin (2018) mukaan ominaista ajoneuvokannan jyrkkä väheneminen. Varaosien valmistamisen päättymisen jälkeen OEM-valmistajat usein tekevät viimeisen tilauksen (Last Time Buy, LTB). Viimeisellä tilauksella tarkoitetaan strategiaa vanhentumisen vaikutusten minimoimisille, jossa ostetaan varastoon tietty määrä osia tuotteen jäljellä olevan elinkaaritaipeen kattamiseksi. Ongelmana on kuitenkin viimeisen tilauksen koko eli varaosien kysynnän selvittäminen tuotteen jäljellä olevalle elinkaarelle. (Klug 2018; Fortuin 1980).

Viimeisen tilauksen koon eli elinkaaritaipeen yliarvioimen, on mahdollisesti syynä Cohenin ym. (2006) havaintoon varaosien vanhentumisesta.

### 3.3 Varaosien kysyntään vaikuttavat tekijät

Loukmidiksen ja Luczakin (2006) mukaan varaosien kysyntään vaikuttavat tekijät voidaan jakaa neljään eri pääkategoriaan: ajoneuvoon, varaosaan, huoltoon ja varaosamarkkinoihin ja muihin ulkoisiin tekijöihin liittyviin tekijöihin. Nämä kategoriat voidaan taas avata syvemmälle seuraavasti:

- Ajoneuvoon liittyvät tekijät: Varaosien kysyntään vaikuttavat käytössä olevien ajoneuvojen määrä, niiden suunniteltu myynti tulevaisuudessa, ajoneuvojen kannan ikärakenne, käytössä olevien ajoneuvojen käyttöaste ja käyttöolosuhteet.
- Varaosaan liittyvät tekijät: Varaosien kysyntään vaikuttajat varaosien käyttöikä, niiden kulutuskestävyys, käyttöintensiiviteetti, käyttöolosuhteet sekä varaosien modulaarisuus.
- Huoltoon liittyvät tekijät: Varaosien kysyntään vaikuttavat ajoneuvolle tehtävät huoltotoimenpiteet, tarkastukset, korjaukset ja päivitykset.
- Varaosamarkkinoihin ja muihin ulkoisiin tekijöihin liittyvät tekijät: Varaosien kysyntään vaikuttavat myös muiden kuin alkuperäistoimittajien tulo markkinoille, varaosien poistuminen markkinoilta ja lainsäädännön vaatimukset ja teknologia.

Tarkastellaan seuraavaksi tarkemmin näitä pääkategorioita.

#### 3.3.1 Ajoneuvoon liittyvät tekijät

Varaosien kysynnän johdannaisuuteen takia ajoneuvojen myynti ja käyttö on varaosien kysynnän perusedellytys. Täten, mitä enemmän tiettyä ajoneuvoa on markkinoilla ja mitä enemmän niitä käytetään, sitä suurempi on varaosien potentiaalinen kysyntä. Tämän lisäksi Loukmidiksen ja Luczakin (2006) mukaan ajoneuvojen ikärakenne, käyttöaste ja käyttöolosuhteet vaikuttavat varaosien kysyntään.

Eri ihmisillä on luonnollisesti erilaiset käyttötavat ja tarpeet autolle, jotka heijastuvat myös ajosuoritetilastoissa. Vuonna 2018 bensiinikäyttöisillä henkilöautoilla ajettiin keskimäärin noin 11 tuhatta kilometriä vuodessa, kun taas dieselkäyttöisillä keskimäärin noin 20 tuhatta kilometriä. Keskimääräinen ajosuorite samana vuonna oli noin 13,8 tuhatta kilometriä. (Tilastokeskus 2019). Zhang ym. (2021) tukee Loukmidiksen ja

Luczakin (2006) ajatusta käyttöasteen ja olosuhteen vaikutuksesta varaosien kysyntään. Heidän mukaan yksityishenkilöiden autojen käyttö vaihtelee merkittävästi, joka voi luoda merkittävää vaihtelua varaosien ja huollon tarpeisiin.

Tilastokeskuksen (2019) mukaan on havaittavissa eroavaisuuksia yritysten ja yksityisten autojen käytössä. Yritysautoilla ajettiin keskimääräisesti noin 18,5 tuhatta kilometriä vuonna 2018, joka on selvästi enemmän kuin yksityisautoilla. Suurempi ajosuorite todennäköisesti lisää huoltotarvetta verrattuna yksityiskäytössä oleviin autoihin.

Zhangin ym. (2021) mukaan yritykset usein ostavat useita samankaltaisia ajoneuvoja, joilla on tyypillisesti sama käyttöaste ja -ympäristö, jolloin varaosien ja huollon tarpeet ovat hyvin samankaltaisia ajoneuvojen välillä yrityksen sisällä. Kuitenkin ajoneuvojen käyttö eroaa merkittävästi eri yritysten välillä, sillä Tilastokeskuksen (2019) mukaan esimerkiksi takseilla ajettiin keskimäärin noin 61,7 tuhatta kilometriä vuodessa, joka on moninkertaisesti enemmän kuin yritysautoilla keskimäärin.

### 3.3.2 Varaosaan liittyvät tekijät

Loukmidiksen ja Luczakin (2006) mukaan myös varaosien käyttöiällä on suuri vaikutus kysyntään, sillä varaosan pidempi käyttöikä johtaa sen kysynnän vähenemiseen.

Tässäkin tapauksessa varaosien kulutuskestävyydellä, käyttöintensiteetillä ja olosuhteilla on vaikutus samoin kuin ajoneuvonkin osalta. Ajo-olosuhteiden ja käytön vaikutusta eri osien kulumiseen ja täten niiden vaihtoväliin on tutkittu. Esimerkiksi Świderskin ym. (2019) mukaan liikennetyypillä ja ajokuukaudella on tilastollisesti merkitsevä vaikutus jarrujen kulumiseen.

Loukmidiksen ja Luczakin (2006) mukaan varaosien kysyntään vaikuttaa myös saatavilla oleva varaosavalikoima. Heidän mukaansa standardiosien käytön lisääntyminen tai useiden osien yhdistäminen moduuleiksi voi lisätä yksittäisen varaosan kysyntää ja parantaa niiden ennustavuutta. Ajoneuvojen pohjalevystrategioiden eli yhteisen rakenneosien kokonaisuuden käyttäminen on ajoneuvoteollisuudessa tyypillistä. Samojen osien käyttämisellä useissa eri ajoneuvoissa voidaan saavuttaa mittakaavaetuja ja vähentää kehityskuluja sekä osien valmistuskustannuksia. (Muniz & Belzowski 2017.) Valmistajien valitsema strategia yksinkertaistaa myös varaosien ennustamista, sillä samat osat voivat sopia useisiin malleihin.

### 3.3.3 Huoltoon liittyvät tekijät

Ajoneuvojen huoltokäytännöt voidaan käytännössä jakaa kahteen pääryhmään: korjaus- ja huoltotoimintaan. Korjaustoimenpiteissä kyse on rikkoutuneiden osien vaihtamisesta, ja näin ollen näiden toimenpiteiden kysyntä riippuu osan vikaantumistodennäköisyydestä ja on siksi tilastollinen. (Loukmidis & Luczak 2006.) Huoltotoimenpiteet ovat sen sijaan ennaltaehkäiseviä toimenpiteitä, jossa osat vaihdetaan uusiin esimerkiksi määrätyn huoltovälin ylittymisen jälkeen. Tämän takia näiden ennaltaehkäisevien toimenpiteiden käyttämien varaosien kysyntä on enimmäkseen ennakoitavissa ajoneuvon käytön ja valmistajan huoltokäytäntöjen pohjalta. Tämän lisäksi osa ajoneuvoista kykenee myös diagnosoimaan automaattisesti tulevia vikoja, jolloin osat pystytään tilamaan jo etukäteen ennen osan rikkoutumista. Tämä mahdollistaa entistä nopeammat huollot asiakkaille ja lyhentää laiteseisokkeja.

Ajoneuvojen huoltokäytännöt eroavat myös toisistaan riippuen valmistajasta, mallista ja moottorityypistä. Autojen määräaikaishuoltojen huoltovälit ja -kohteet ovat valmistajan määrittelemiä, ja niiden noudattaminen on usein takuun säilymisen ehto. Tämän takia määräaikaishuollot todennäköisesti tehdään ajallaan ainakin takuun voimassaolon ajan, joka vaihtelee tyypillisesti kahdesta seitsemään vuoteen.

### 3.3.4 Varaosamarkkinoihin liittyvät tekijät

Loukmidiksen ja Luczakin (2006) mukaan edellä kuvattujen syiden lisäksi myös varaosamarkkinoiden rakenne ja muut ulkoiset tekijät vaikuttavat varaosien kysyntään. Heidän mukaansa varaosien kysyntään vaikuttavat markkinoilla olevan varaosatarjonnan rakenne kuten tarvikeosien saatavuus, varaosatarjonnan muutokset ja ulkoiset tekijät kuten lainsäädännölliset vaatimukset tai uuden teknologian käyttöönotto. Varaosatarjonnan rakenne voi vaikuttaa yksittäisten osien kysyntään esimerkiksi sellaisissa tilanteissa, joissa osasta on runsaasti saatavilla käytettyjä, tehdaskorjattuja tai tarvikevaraosia. Tällaisissa tilanteissa asiakas saattaa esimerkiksi valita olla ostamatta uutta osaa.

Ajoneuvojen sähköistyminen mahdollisesti lisää myös osien uudelleenvalmistusta. Hustlerin ym. (2022) mukaan sähkö- ja hybridautojen akkujen uudelleenvalmistaminen voisi vähentää uusien varaosa-akkupakettien kysyntää riippuen uudelleenvalmistettujen hinnasta ja niille myönnettävästä takuusta.

## 4 Ratkaisuja

Driessenin ym. (2010) mukaan varaosien kysyntää voidaan ennustaa joko historiatietojen, kysyntää koskevien ennakkotietojen tai näiden yhdistelmän perusteella. Luvuissa 4.1 ja 4.2 käsitellään historialliseen dataan perustuvia aikasarjamenetelmiä, jotka voidaan jakaa parametrisiin ja ei-parametrisiin menetelmiin. Luvussa 4.3 käsitellään menetelmiä, jotka hyödyntävät tietoa asennetusta laitekannasta kysynnän ennakoimiseksi.

### 4.1 Epäsäännöllisen kysynnän menetelmät

Epäsäännöllisen kysynnän ennustamiseksi on kehitetty erityisiä parametrisiä menetelmiä, joista todennäköisesti tunnetuin on Crostonin malli (ks. Croston 1972). Croston (1972) jakaa aikasarjan kahteen erilliseen komponenttiin: kysynnän suuruuteen ja kysyntöjen aikaväleihin. Näitä komponentteja käsitellään ennustaessa toisistaan riippumattomina ja jotka tasoitetaan käyttäen eksponentiaalista tasoitusta. Crostonin malli voidaan esittää matemaattisesti muodossa

$$\text{jos } X_t > 0, \begin{cases} Z_{t+1} = \alpha X_t + (1 - \alpha)Z_t \\ V_{t+1} = \alpha q + (1 - \alpha)V_t \\ Y_{t+1} = \frac{Z_{t+1}}{V_{t+1}} \end{cases}$$

$$\text{jos } X_t = 0, \begin{cases} Z_{t+1} = Z_t \\ V_{t+1} = V_t \\ Y_{t+1} = Y_t \end{cases}$$

missä

$Z_t$  = kysyntöjen suuruuskomponentti

$V_t$  = kysyntöjen aikavälikomponentti

$Y_{t+1}$  = ennuste seuraavalle ajanjaksolle

$X_t$  = toteutunut kysyntä

$\alpha$  = tasoituserroin välillä  $[0,1]$

$q$  = peräkkäisten nollakysyntä-aikajaksojen määrä

Crostonin mallissa ennuste päivittyy vain, kun kysyntä ilmaantuu. Crostonin (1972) mukaan tällä saavutetaan merkittävästi tarkempia ennusteita verrattuna yksinkertaiseen eksponentiaaliseen tasoitukseen (SES, Simple Exponential Smoothing, kts. luku 2.2.3) epäsäännöllisen kysynnän tapauksissa. Boylanin ja Syntetosin (2021, 131) mukaan Crostonin menetelmän etuna on identtisyys perinteisen eksponentiaalisen tasoituksen kanssa tilanteissa, joissa kysyntää on jokaisella jaksolla. Heidän mukaansa täten menetelmää voidaan käyttää epäsäännöllisen kysynnän ennustamiseksi myös muihin tuotteisiin.

Syntetos ja Boylan (2001) kritisoivat Crostonin mallia sen sisältämän sisäisen vääristymän takia. Tämän vääristymän korjaamiseksi on luotu mm. Syntetos-Boylan-approksimaatio (SBA, ks. Syntetos & Boylan 2005) ja Teunter-Syntetos-Babai-menetelmä (TSB, ks. Teunter ym. 2011). SBA pyrkii korjaamaan tämän sisäisen vääristymän, ja eroaa Crostonin menetelmästä ainoastaan ennustefunktioltaan. Korjattu ennustefunktio on mallia

$$Y_{t+1} = \left(1 - \frac{\alpha}{2}\right) \frac{Z_{t+1}}{V_{t+1}}$$

missä

$Z_t$  = kysyntöjen suuruuskomponentti

$V_t$  = kysyntöjen aikavälikomponentti

$Y_{t+1}$  = ennuste seuraavalle ajanjaksolle

$\alpha$  = tasoituskerroin välillä  $[0,1]$ . (Syntetos & Boylan 2005.)

TSB-menetelmä eroaa edellä esitetyistä menetelmistä erityisesti siten, että se arvioi kysynnättömien ajanjaksojen esiintymisen todennäköisyyttä. Tämän lisäksi mallissa ennustetta päivitetään jokaisella ajanjaksolla. Kyseinen malli voidaan esittää matemaattisesti muodossa

$$\text{jos } X_t > 0, \begin{cases} p_{t+1} = p_t + \beta(1 - p_t) \\ Z_{t+1} = Z_t + \alpha(X_t - Z_t) \\ Y_{t+1} = P_{t+1}Z_{t+1} \end{cases}$$



$$\text{jos } X_t = 0, \begin{cases} p_{t+1} = p_t + \beta(1 - p_t) \\ Z_{t+1} = Z_t \\ Y_{t+1} = P_{t+1}Z_{t+1} \end{cases}$$

missä

$Z_t$  = kysyntöjen suuruuskomponentti

$p_t$  = kysynnän esiintymisen todennäköisyys

$Y_{t+1}$  = ennuste seuraavalle ajanjaksolle

$X_t$  = toteutunut kysyntä

$\alpha, \beta$  = tasoituskerroin välillä  $[0,1]$ . (Teunter ym. 2011.)

TSB-menetelmässä nollakysyntäjaksot laskevat kysynnän esiintymisen todennäköisyyttä ja täten myös ennuste seuraavalle jaksolle laskee. Boylanin ja Syntetosin (2021, 270) mukaan tämä on toivottavaa, kun tuotteen arvioidaan olevan elinkaarensa loppupuolella, jolloin tehdään päätöstä varastoinnin jatkamisesta. Heidän mukaansa TSB-menetelmän ennusteet ovat vähemmän relevantteja tuotteille, jotka eivät ole elinkaarensa lopussa. Koska TSB-menetelmän ennuste päivittyy jokaisen jakson jälkeen, kykenee se reagoi nopeammin muutoksiin kuin Crostonin menetelmä tai SBA, ja on täten sopivampi tuotteille, joissa on vanhentumisen riski.

TSB:n lisäksi mm. SBA:han on tehty korjauksia, jotka pyrkivät huomioimaan varastojen vanhentumisen riskin (ks. Babai ym. 2019). Babain ym. (2019) mallissa kysynnän ollessa positiivinen päivitetään ennuste SBA-menetelmän mukaisesti. Jaksoilla, jossa kysyntä on nolla, mikäli edellisestä positiivisesta kysynnästä kulunut aika ylittää SBA:n aikavälikomponentin, päivitetään ennuste TSB-menetelmän mukaisesti. Mallin on näytetty antavan tarkempia ennusteita kuin SBA:n tai TSB:n tilanteissa, joissa on vanhentumisen riski.

Näiden kahden menetelmän lisäksi on myös muita vanhentumisen riskin huomioivia epäsäännöllisen kysynnän ennustamiseen suunniteltuja malleja, kuten hyperbolinen eksponentiaalinen tasoitus (Hyperbolic-Exponential Smoothing, HES, ks. Prestwich ym. 2014) ja eksponentiaalinen tasoitus lineaarisella rappeutumisella (Exponential Smoothing with Linear Decay, ESLD, ks. Prestwich ym. 2021). Boylanin ja Syntetosin

(2021, 272) mukaan TSB- ja HES-menetelmien suhteellisista eduista tarvitaan lisää empiiristä tutkimusta.

## 4.2 Bootstrapping-menetelmät

Syntetosin ym. (2015) mukaan ei-parametriset-lähestymistavat voivat antaa tarkempia tuloksia, kun kysynnän suuruuden vaihtelu kasvaa, jolloin kysynnän todellinen suurusjakauma ei välttämättä vastaa mitään teoreettista standardijakaumaa. Ei-parametriset menetit kuten bootstrapping-menetelmät eivät perustu mihinkään teoreettiseen jakaumaoletukseen, toisin kuin yllä esitetyt parametriset menetit.

Syntetosin ym. (2015) mukaan bootstrapping-menetelmät ottavat useita satunnaisotoksia suuremmasta otoksesta tai itse perusjoukosta. Nämä otokset voivat poiketa toisistaan ja perusjoukosta, ja niiden avulla muodostetaan histogrammi kysynnästä. Tästä histogrammista lasketaan tilastolliset tunnusluvut kuten keskiarvo ja varianssi, sen sijaan, että ne johdettaisiin jostain teoreettisesta jakaumasta.

Bootstrapping-menetelmiä on kirjallisuudessa esitetty useita mm. Efron (1979), Willemain ym. (2004), Zhou & Viswanathan (2011). Kuitenkin Willemain – Smart – Schwar-menetelmä (WSS, ks. Willemain ym. 2004) on tunnetuin varaosien ajoittaisen kysynnän ennustamiseen tarkoitettu bootstrapping-menetelmä (Hasni ym. 2019a). WSS-menetelmässä hyödynnetään bootstrappingin lisäksi Markovin-ketjua ja 'jitterointia' ennusteen luomiseksi. WSS-metodin vaiheet on esitetty alla olevassa kuviossa.

<p>Vaihe 0. Historiallisten kysyntätietojen hankinta</p> <p>Vaihe 1. Siirtymätodennäköisyyksien eli kysynnän esiintymisen todennäköisyyden määrittäminen kaksitilaiselle Markovin ketjulle.</p> <p>Vaihe 2. Binäärisen eli kysyntää/ei-kysyntää aikasarjan luominen Markovin ketjulla.</p> <p>Vaihe 3. Korvataan jokainen nolasta poikkeava arvo satunnaisesti kysyntähistogrammista poimitulla luvulla</p> <p>Vaihe 4. 'Jitteroidaan' nolasta poikkeavat arvot</p> <p>Vaihe 4.1 <math>X' = 1 + \text{INT}(X + Z\sqrt{X})</math>, jossa <math>X'</math> on 'jitteroitu' kysyntä, <math>X</math> on histogrammista poimittu toteutunut kysyntä ja <math>Z</math> on normaalijakautunut satunnaismuuttuja</p> <p>Vaihe 4.2 Jos <math>X' \leq 0</math>, niin <math>X' = X</math></p> <p>Vaihe 5. Lasketaan kaikki arvot yhteen ennustejaksolta</p> <p>Vaihe 6. Toistetaan vaiheet 2 – 5 tuhat kertaa</p> <p>Vaihe 7. Käytetään syntyvää jakaumaa ennusteena</p>
--

Kuva 4 WSS-menetelmän vaiheet (mukaillen Willemain ym. 2004; Hasni ym. 2019b)

WSS-menetelmässä luodaan kaksitilaisen Markovin ketjun ja saatavilla olevan datan pohjalta laskettujen siirtymätodennäköisyyksien avulla kysynnän ennusteaikasarja, jonka osilla voi olla kaksi tilaa: nolla eli ei kysyntää ja yksi eli kysyntää. Tämän jälkeen jokainen nolasta poikkeava arvo korvataan satunnaisesti valitulla todellisen kysynnän arvolla. Tämän jälkeen näihin nolasta poikkeaviin arvoihin lisätään varianssia 'jitteroimalla', jonka jälkeen aikasarjan jäsenet lasketaan yhteen. Toistamalla vaiheita 2 – 5 riittävän monta kertaa, saadaan lopputulokseksi arvio ennustejakson kysynnän jakaumasta, jota käytetään ennustamiseen.

Willemain ym. (2004) vertasivat tutkimuksessaan luomaansa WSS-menetelmää Crostonin-menetelmään. Heidän mukaansa WSS tuotti tarkempia ennusteita kuin Croston 28 000 varastointiyksikköön pohjautuvalla datalla. Syntetos ym. (2015) vertasivat tutkimuksessaan WSS-menetelmää parametrisiin SBA-, Crostonin- ja SES-menetelmiin käyttäen dataa vähittäiskaupan korumyynneistä ja elektroniikan varaosista. Tutkimuksen mukaan korujen osalta WSS oli marginaalisesti parempi kuin muut, mutta elektroniikan osalta muut menetelmät olivat huomattavasti parempia tarkasteltaessa jälkitoimitusten määrää. Hasni ym. (2019b) vertasivat tutkimuksessaan WSS- ja SBA-menetelmiä sekä VZ-menetelmää (kts. Zhou & Viswanathan 2011) toisiinsa. Heidän

mukaansa näiden kolmen ennustemenetelmän suhteellisesta suorituskyvystä saadut havainnot olivat ristiriitaisia.

Boylanin ja Syntetosin (2021, 302) mukaan WSS-menetelmän vahvuutena on sen kyky käsitellä epätyypillisiä kysyntämalleja. Heidän mukaansa se on tästä huolimatta laskennallisesti vaativampi kuin parametriset menetelmät kuten SBA, joka voi olla perusteltua, mikäli mallilla voidaan saada tarkempia ennusteita. Kuitenkin empiirinen näyttö tästä on jokseenkin vaihtelevaa.

### **4.3 Asennetun laitekannan tieto**

Van der Auerwarerin ym. (2019) mukaan asennetun laitekannan tieto (installed base information, IBI) koostuu kolmesta varaosien kysyntää ohjaavasta tietolähteestä, jotka ovat (1) asennetun laitekannan koko ja tila sekä varaosan tila, (2) huoltokäytännöt ja (3) osien luotettavuuteen vaikuttavat ympäristötekijät. Nämä kategoriat ovat kohtalaisen yhteneviä luvussa 3.3 esitettyihin varaosaan kysyntään vaikuttavien tekijöiden kanssa. Dekkerin ym. (2013) mukaan asennetun laitekannan tietojen kerääminen edellyttää laitteen koko rakenteen ymmärtämistä ja mahdollisten teknisten parannusten ja huoltotoimintojen seuraamista. Anderssonin ja Jonssonin (2018) mukaan näitä tietoja voidaan hyödyntää kolmessa eri tyypisessä kausaaliennusteessa. Heidän mukaansa nämä tyypit ovat varaosan luotettavuuspohjainen ennustaminen, regressiopohjainen ennustaminen ja kunnossapitopohjainen ennustaminen.

Van der Auerwarer ym. (2021) tarkastelivat tutkimuksessaan neljää eri varaosan luotettavuuteen perustuvaa ennustemallia ja kahta regressiomallia verraten näitä SES- ja SBA-aikasarjamenetelmiin. Nämä verrokkimenetelmät eivät ota huomioon lainkaan asennetun laitekannan tietoa. Tutkimuksen mukaan asennetun laitekannan tietojen huomioiminen ennustemalleissa ja varastointistrategioissa vähentää kustannuksia verrattuna aikasarjamenetelmiin erityisesti silloin, kun asennetun kannan koko vaihtelee. Heidän mukaansa suurin hyöty saavutetaan aktiivisen laitekannan koon tuntemisella, joka määräytyy uusien myynnin ja vanhojen romuttamisen perusteella.

Nämä havainnot tukevat Dekkerin ym. (2013) tutkimusta, jonka mukaan asennetun laitekannan tietojen avulla varaosien kysyntäennusteista voidaan tehdä merkittävästi tarkempia verrattuina malleihin, jotka hyödyntävät vain historiallista kysyntää. Lundhin ja Marklundin (2020) tulokset maisterintutkielmassaan Volvon henkilöautojen osalta

tukevat myös asennetun laitekannan tietojen hyödyntämistä autojen varaosien kysynnässä.

Zhu ym. (2020) esittelivät tutkimuksessaan lentokoneen huoltoaikatauluun perustuvan varastohallinta- ja ennustemenetelmän. He käyttivät tutkimuksessaan dataa lentokoneiden huoltoon ja osiin liittyen, jossa heidän mallinsa pärjasi paremmin kuin parametriset aikasarjamenetelmät. Lentokoneet ja autot kuitenkin eroavat toisistaan huoltotoiminnoiltaan, joka luo epävarmuutta tutkimuksen tulosten suorasta siirrettävyydestä autoihin.

Asennetun laitekannan tietojen hyödyntäminen ei kuitenkaan aina edellytä erityisen mallin rakentamista, vaan sen sijaan asennetun laitekannan tietoja voidaan käyttää perinteisten menetelmien tuottamien ennusteiden muokkaamiseen (Van der Auerwarer ym. 2019). Tämä voisi vähentää tarvetta monimutkaisille ennustamismenetelmille. Jalilin ym. (2011) tutkimuksen mukaan asennetun laitekannan tietojen lisääminen eksponentiaaliseen tasoitukseen pohjautuvaan ennusteeseen on vähentänyt varastointi- ja kuljetuskustannuksia IBM:n tapauksessa.

Asennetun laitekannan tietojen käyttäminen ei kuitenkaan ole ongelmaton. Dekkerin ym. (2013) mukaan ennusteiden laatimiseen tarvittavien tietojen hankkiminen ja niiden hyödyntäminen voi olla hyvin vaikeaa ja aikaa vievää. Tämän lisäksi myös tarvittavien tietojen hallinnointi on haastavaa mm. laitekannan suuren koon, tuotekokoonpanojen muutoksien, sekä tuotteiden että asiakkaiden heterogeenisyyden takia. Suomessa ajoneuvojen osalta asennetun laitekannan tietoja on saatavilla Liikenne- ja viestintävirastolta, joka julkaisee tietoa katsastuksien lukumääristä ja hylkäyksistä mallikohtaisesti. Henkilöautot ovat katsastettava Suomessa ensimmäisen kerran viimeistään neljän vuoden ikäisenä, jonka jälkeen viimeistään kahden vuoden välein, kunnes katsastusväli tihenee vuoteen kymmenen vuoden iässä (Traficom 2020). Asennetun laitekannan tietojen käyttämisen hyödyistä ennustamisessa on kuitenkin selvää näyttöä.

## 5 Yhteenveto ja johtopäätökset

Tässä tutkielmassa tarkasteltiin ajoneuvojen varaosien kysynnän ennustamista.

Tutkielmassa ensin perehdyttiin kysynnän ennustamiseen ja sen menetelmiin, jonka jälkeen ajoneuvojen varaosien erityispiirteisiin ja kysynnän ennustamisen haasteisiin ja viimeiseksi varaosien kysynnän ennustamiseksi suunniteltuihin menetelmiin.

Tutkielman päätutkimuskysymyksenä oli ”*Miten ajoneuvojen varaosien kysyntää voidaan ennustaa?*” Tutkielman perusteella ajoneuvojen varaosien ennustamista varten on kehitetty erityisiä menetelmiä, jotka huomioivat perinteisiä ennustamismenetelmiä paremmin varaosien kysyntään liittyviä erityispiirteitä ja haasteita. Näistä erityisistä ennustamismenetelmistä esiteltiin tarkemmin epäsäännöllisen kysynnän parametriset menetelmät, WSS bootstrap-menetelmä ja asennetun laitekannantietoa hyödyntävät menetelmät.

Empiirinen näyttö eri varaosien ennustamismenetelmien keskinäisestä suorituskyvystä on vaihtelevaa. Ennustemenetelmien suorituskykyä vertailevien tutkimusten käyttämät datasarjat eroavat toisistaan, jolloin tutkimusten tulokset eivät välttämättä ole täysin vertailukelpoisia keskenään. Tutkimusten perusteella voidaan kuitenkin todeta, että epäsäännöllisen kysynnän ennustamiseen suunnitellut mallit antavat tarkempia tuloksia kuin yksinkertaisemmat aikasarjamenetelmät. Lisää empiiristä tutkimusta eri ennustamismenetelmien keskinäisistä suorituskyvyistä kuitenkin tarvitaan.

Asennetun laitekannan tietojen hyödyntämisestä varaosien ennustamisessa on selvää näyttöä etenkin asennetun laitekannan koon vaihdellessa. Driessenin ym. (2010) mukaan tulevaa kysyntää koskevien tietojen kuten asennetun laitekannan tietojen, käyttäminen vähentää yleensä ennustevirhettä, mutta toisaalta niiden käyttäminen lisää ennustamisen vaikeutta, vaivaa ja kustannuksia. Heidän mukaansa suhteellisen halpojen osien osalta tai osien joiden kysyntä on todella pientä näiden tietojen käyttäminen ei ole kustannusten kannalta hyödyllistä.

Toisaalta asennetun laitekannan tietojen hyödyntäminen ei myöskään aina edellytä uuden monimutkaisen mallin rakentamista, vaan olemassa olevaa ennustetta voidaan muokata asennetun laitekannan tietojen perusteella. Tästä huolimatta näiden tietojen hyödyntämiseen liittyy haasteita mm. tietojen hankkimiseen ja niiden hyödyntämiseen. Liikenne- ja viestintävirasto Traficom kuitenkin julkaisee tietoja henkilöautojen

lakisääteisistä katsastuksista, joiden tietoja voidaan hyödyntää osana ennusteita. Avoimen datan avulla myös pienemmällä toimijoilla on mahdollisuus hyödyntää asennetun laitekannan tietoja.

Ennustemenetelmän valinnassa on kuitenkin huomioitava ennustetarkkuuden lisäksi myös muita tekijöitä. Syntetosin (2015) mukaan kuitenkin parametristen menetelmien kuten esiteltyjen epäsäännöllinen kysynnän mallien ymmärtäminen edellyttää vähemmän erityisosaamista, ja täten ne ovat avoimempia ja vähemmän herkkiä mahdollisesti haitallisille harkinnanvaraisille toimenpiteille. Klugin (2018, 507) mukaan käytettävien ennustemallien on aina oltava käyttäjälle läpinäkyviä virheellisten päätösten välttämiseksi. Hänen mukaansa ennustemallin tarkennuksen yhteydessä on myös punnittava sen marginaalihyötyjä ja -kustannuksia. Näiden pohjalta voidaan todeta, että ihmisten luottamuksen rakentamiseksi ennustetta kohtaan ennustemenetelmän valinnassa on syytä kiinnittää huomiota käytettyjen menetelmien ymmärrettävyyteen. Tämän lisäksi valinnassa on syytä punnita ennustetarkkuutta ja menetelmien käyttämisen edellyttämää tietotaitoa ja kustannuksia.

Tämän tutkielman pohjalta jatkotutkimuksen kannalta olisi keskeistä vertailla eri ennustemenetelmiä empiirisellä ajoneuvojen varaosien kysynnän aineistolla. Riittävän laajalla aineistolla voitaisiin tutkia miten eri ennustamismenetelmät pystyvät toimimaan oikeassa ympäristössä ja selventämään niiden keskinäistä suorituskykyä. Tämän lisäksi myös tekoälyn hyödyntämisen mahdollisuuksien tarkastelu voisi olla kannattavaa siihen pohjautuvien ennustemenetelmien käytön kasvaessa. Tällaisella tutkimuksella voisi olla merkittävä käytännöllinen merkitys alan toimijoille sekä se vastaisi aiemmin esiteltyyn tutkimustarpeeseen.

## Lähteet

- Anderssen, J. – Jonsson, P. (2018) Big data in spare parts supply chains: The potential of using product-in-use data in aftermarket demand planning. *International Journal of Physical Distribution & Logistics Management*, Vol. 48 (5), 525 – 544.
- Atiya, A. (2020) Why does forecast combination work so well? *International Journal of Forecasting*, Vol. 36, 197 – 200.
- Babai, M. – Boylan, J. – Rostmani-Tabar, B. (2022) Demand forecasting in supply chains: a review of aggregation and hierarchical approaches. *International Journal of Production Research*, Vol. 60 (1).
- Babai, M. – Dallery, Y. – Boubaker, S. – Kalai, R. (2019) A new method to forecast intermittent demand in the presence of inventory obsolescence. *International Journal of Production Economics*, Vol. 209, 30 - 41.
- Boylan, J. – Syntetos, A. (2010) Spare parts management: a review of forecasting research and extensions. *IMA Journal of Management Mathematics*, Vol. 21 (3), 227 – 237.
- Boylan, J. – Syntetos, A. (2021) Intermittent Demand Forecasting: Context, Methods and Applications. Wiley, Hoboken.
- Cohen, M.A. – Agrawal, N. – Agrawal, V. (2006) Winning in the aftermarket. *Harvard Business Review*, Vol. 84, 129 – 138.
- Clemen, R. (1989) Combining forecasts: A review and annotated bibliography. *International Journal of Forecasting*, Vol. 5 (4), 559 – 583.
- Dekker, R. – Pinçe, Ç – Zuidwijk, R – Jalil, M. (2013) On the use of installed base information for spare parts logistics: A review of ideas and industry practice. *International Journal of Production Economics*, Vol. 143 (2), 536 – 545.
- Driessen, M.A. – Arts, J.J. – van Houtum, G.J. – Rustenburg, W.D. – Huisman, B. (2010) Maintenance spare parts planning and control: A framework for control and agenda for future research. *BETA publicatie: working papers*, Vol. 325. Technische Universiteit Eindhoven.
- Efron, B. (1979) Bootstrap Methods: Another Look at the Jackknife. *The Annals of Statistics*, Vol. 7 (1), 1 – 26.



- Fortuin, L. (1980) The All-Time Requirement of Spare Parts for Service After Sales – Theoretical Analysis and Practical Results. *International Journal of Operations & Production Management*. Vol. 1 (1), 59 – 70.
- Holt, C. (2004) Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, Vol. 20 (1), 5 – 10.
- Hunster, S. – Glöser-Chahoud, S. – Rosenberg, S. – Schultmann, F. (2022) A simulation model for assessing the potential of remanufacturing electric vehicle batteries as spare parts. *Journal of Cleaner Production*, Vol. 363, 132225.
- Hyndman, R. – Athanasopoulos, G. (2018) *Forecasting: Principles and Practice*. 2. painos. OTexts, Melbourne.
- Jalil, M. – Zuidwijk, R. – Fleischmann, M. – van Nunen, J. (2011) Spare parts logistics and installed base information. *Journal of Operational Research Society*, Vol. 62 (3), 442 – 457.
- Kennedy, W.J. – Patterson, J.W. – Fredendall, L.D. (2002) An overview of recent literature on spare parts inventories. *International Journal of Production Economics*, Vol. 76 (2), 201 – 215.
- Klug, F. (2018) *Logistikmanagement in der Automobileindustrie: Grundlagen der Logistik im Automobilbau*. 2. painos. Springer Vieweg Verlage, Berlin.
- Kolassa, S. – Siemensen, E. (2016) *Demand forecasting for managers*. Business Expert Press, New York.
- Loukmidis, G. – Luczak, H. (2006) Lebenszyklusorientierte Planungsstrategien für den Ersatzteilbedarf. Teoksessa: *Erfolgreich mit After Sales Services: Geschäftsstrategien für Servicemanagement und Ersatzteillogistik*, toim. Barkwawi, K. – Baader, A. – Montanus, S., 251 – 270. Springer-Verlag, Berlin.
- Lundh, A. – Marklund, M. (2020) *Forecasting Initial Phase Spare Part Demand using Installed Base Data: A Study at Volvo Cars*. Pro gradu -tutkielma, Chalmers University of Technology.
- Mentzer, J – Moon, M. (2005) *Sales forecasting management a demand management approach*. SAGE, London.
- Moon, M. (2018) *Demand and Supply Integration: The Key to World-Class Demand Forecasting*, 2. painos. Walter de Gruyter Inc, Berlin.
- Muniz, S. – Belzowski, B. (2017) Platforms to enhance electric vehicles' competitiveness. *International Journal of Automotive Technology and Management*, Vol. 17 (2), 151 – 168.

- Prestwich, S.D. – Tarim, S.A. – Rossi, R. – Hnich, B. (2014) Forecasting intermittent demand by hyperbolic-exponential smoothing. *International Journal of Forecasting*, Vol. 30 (4), 928-933.
- Prestwich, S.D. – Tarim, S.A. – Rossi, R. (2021) Intermittency and obsolescence: A Croston method with linear decay. *International Journal of Forecasting*, Vol. 37, 708 – 715.
- Rezapour, S. – Allen, J.K – Mistree, F. (2016) Reliable flow in forward and after-sales service supply chains. *Transportation Research. Part E, Logistics and Transportation Review*, Vol. 93, 309 – 436.
- Sanders, N. – Ritzman, L. (2004) Integrating judgemental and quantitative forecasts: methodologies for pooling marketing and operations information. *International Journal of Operations & Productgion Management*, Vol. 24 (5), 514 – 529.
- Świdorski, A. – Borucka, A. - Jacyna-Golda, I. – Szczepański, E. (2019) Wear of brake system components in various operating conditions of vehicle in the transport company. *Eksploatacja i Niezawodność – Maintenance and Reliability*, Vol 21 (1), 1 – 9.
- Syntetos, A – Boylan, J. (2001) On the bias of intermittent demand estimates. *International Journal of Production Economics*, Vol. 71, 457 – 466.
- Syntetos, A. – Babai, Z, - Gardner, E. (2015) Forecasting intermittent inventory demands: simple parametric methods vs. bootstrapping. *Journal of Business Research*, Vol. 68 (8), 1746 – 1752.
- Syntetos, A. – Boylan, J. – Croston, J. (2005) On the categorization of demand patterns. *Journal of the Operational Research Society*, Vol. 56 (5), 495 – 503.
- Syntetos, A. – Boylan, J. (2005) The accuracy of intermittent demand estimates. *International Journal of Forecasting*, Vol. 21 (2), 303 – 314.
- Teunter, R. – Syntetos, A. – Babai, M. (2011) Intermittent demand: linking forecasting to inventory obsolescence. *European Journal of Operational Research*, Vol. 214 (3), 606 – 615.
- Tilastokeskus (2019) Tieliikenteen ajokilometreissä edelleen hienoista kasvua. <<https://www.stat.fi/tietotrendit/artikkelit/2019/tieliikenteen-ajokilometreissa-edelleen-hienoista-kasvua/>>, haettu 17.2.2023.
- Traficom (2020) Katsastusajankohdat ajoneuvoluokittain. <[www.traficom.fi/fi/liikenne/tieliikenne/katsastusajankohdat-ajoneuvoluokittain](http://www.traficom.fi/fi/liikenne/tieliikenne/katsastusajankohdat-ajoneuvoluokittain)>, haettu 24.3.2024.

- Van der Auweraer, S. – Boute, R. – Syntetos, A. (2019) Forecasting spare part demand with installed base information: A review. *International Journal of Forecasting*, Vol. 35, 181 – 196.
- Van der Auweraer, S. – Zhu, S. – Boute, R. (2021) The value of installed base information for spare part inventory control. *International Journal of Production Economics*, Vol. 239, 108186.
- Van der Auwerar, S – Boute, R (2019) Forecasting spare part demand using service maintenance information. *International Journal of Production Economics*, Vol. 213, 138 – 149.
- Waas, A. – Beck, M. – Herzberg, R. – Hauser, J. – Schlehuber, F. – Wolk, A. – Nikolic, Z. (2021) At the Crossroads: The European Aftermarket in 2030. <  
<https://www.bcg.com/crossroads-european-aftermarket-2030>>, haettu 27.2.2024.
- Winters, P. (1960) Forecasting Sales by Exponentially Weighted Moving Averages. *Management Science*, Vol. 6 (3), 324 -342.
- Zhang, S. – Huang, K. – Yuan, Y. (2021) Spare Parts Inventory Management: A literature Review. *Sustainability*, Vol. 13 (2460), 1 – 23.
- Zhou, C. – Viswanathan, S. (2011) Comparison of a new bootstrapping method with parametric approaches for safety stock determination in service parts inventory systems. *International Journal of Production Economics*, Vol. 133 (1), 481 – 485.
- Zhu, S. – Jaarsveld, W.V. – Dekker, R. (2020) Spare parts inventory control based on maintenance planning. *Reliability Engineering and System Safety*, Vol. 193, 106600.