TUOTANTOTALOUDEN KOULUTUSOHJELMA

Kysynnän ennustamisen ja kapasiteetin hallinnan kehitysmahdollisuudet Okmetic Oy:ssä

Demand forecasting and capacity management development in Okmetic Oy

Kandidaatintyö

Sakari Miettinen

TIIVISTELMÄ

Tekijä: Sakari Miettinen

Työn nimi: Kysynnän ennustamisen ja kapasiteetin hallinnan kehitysmahdollisuudet Okmetic Oy:ssä.

Vuosi: 2021 **Paikka:** Lappeenranta

Kandidaatintyö. LUT-yliopisto, Tuotantotalous.
26 sivua, 7 kuvaa ja 1 liite
Tarkastaja: Annastiina Rintala

Hakusanat: kysynnän ennustaminen, kapasiteetin hallinta, kvalitatiiviset menetelmät, kvantitatiiviset menetelmät, regressioanalyysi
Keywords: demand forecasting, capacity management, qualitative methods, quantitative methods, regression analysis

Tämä kandidaatintyö käsittelee kvalitatiivisia ja kvantitatiivisia kysynnän ennustamismenetelmiä. Työ on toteutettu Okmetic Oy:n toimeksiantona. Sen tavoitteena on kartoittaa kysynnän ennustamismenetelmiä, joita voisi hyödyntää kohdeyrityksessä. Työ on tehty kirjallisuuskatsauksena, mutta Okmeticin tiedoista osa on saatu haastattelemalla Okmeticin henkilöstöä.

Työssä käsitellään kvantitatiivisista kysynnän ennustamismenetelmistä kausaali- ja aikasarjamalleja, sekä kvalitatiivisista erityisesti *Sales Force Composite* -menetelmää. Työssä sivutaan myös puolijohdeteollisuudessa olleita sekä tekoälyä hyödyntäviä ennustamismenetelmiä. Kysynnän ennustamiseen liittyviä ongelmia käsitellään yleisesti, mutta paneudutaan erityisesti ongelmiin, joita Okmeticissa voi ilmaantua. Esille tuodaan kysynnän ennustamisen merkitys kapasiteetin hallinnan näkökulmasta, sekä tarkastellaan kapasiteetin hallinnan kehitysmahdollisuuksia. Lopuksi on esitelty regressioanalyysiä soveltava malli ja ennustetarkkuutta seuraava mittari, joita hyödyntämällä voidaan saada ratkaisuja piiskavaikutuksen ja ennustevirheiden juurisyihin.

SISÄLLYSLUETTELO

1 JOHDANTO 3

1.1 Työn rajaus ja tavoite 4

1.2 Työn rakenne 4

2 KYSYNNÄN ENNUSTAMINEN 5

2.1 Kvalitatiiviset ennustamismenetelmät 6

2.1.1 Delfoi -menetelmä 6

2.1.2 Markkina-analyysi 7

2.1.3 Sales Force Composite -menetelmä 8

2.2 Kvantitatiiviset ennustamismenetelmät 8

2.2.1 Aikasarjamallit 9

2.2.2 Kausaalimallit 11

2.3 Yhdistelmämenetelmät 14

2.4 Tekoäly kysynnän ennustamisen työkaluna 14

2.5 Kysynnän ennustamisen haasteet 16

2.6 Ennustetarkkuus 17

2.7 Kysynnän ennustaminen puolijohdeteollisuudessa 18

3 KYSYNNÄN ENNUSTAMINEN OKMETIC OY:SSÄ 20

3.1 Yritysesittely 20

3.2 Ennustamismenetelmien soveltuvuus Okmeticille 21

3.3 Kapasiteetin hallinnan kehittäminen 24

4 JOHTOPÄÄTÖKSET 25

LÄHTEET 27

LIITTEET

1 JOHDANTO

Ennustaminen on elintärkeää jokaiselle yritykselle. Se luo pohjan liiketoiminnan suunnittelulle ja päätöksenteolle (Jacobs & Chase 2017, s. 46). Olennaisena osana yritystoimintaa on tuotteiden tai palveluiden kysyntä. Sitä täytyy pyrkiä ennustamaan, jotta yritystoimintaa voidaan suunnitella. Kysynnän ennustamisen hyöty näkyy muun muassa tehokkaassa kapasiteetin hallinnassa, joka lopulta parantaa yrityksen tulosta.

Ennustaminen voidaan jakaa strategiseen ja taktiseen ennustamiseen. Strategiset ennusteet keskittyvät keskipitkään ja pitkään aikaväliin. Niitä hyödynnetään strategisessa päätöksenteossa, ja ne voivat liittyä esimerkiksi kapasiteettiin, tuotantoprosessiin tai toiminnan kokonaissuunnitteluun. Taktiset ennusteet taas keskittyvät lyhyeen aikaväliin, ja niitä hyödynnetään esimerkiksi tuotteiden saatavuuden varmistamisessa. (Jacobs & Chase 2017, s. 46) Tässä kandidaatintyössä keskitytään strategiseen ennustamiseen ja tutkitaan sen vaikutuksia pitkän aikavälin kapasiteetin suunnitteluun.

Kapasiteettia pidetään määränä, jota systeemi pystyy tuottamaan tietyn aikaikkunan sisällä. Pitkän aikavälin kapasiteetin suunnitteluun kuuluu kapasiteettiin vaikuttavat hankinnat, joita ovat muun muassa kiinteistöt ja laitteet. Strategisen kapasiteetin hallinnan tehtävä on luoda näkymä kokonaiskapasiteettitasosta, johon kuuluu pääomavaltaisia tekijöitä kuten toimitilat, laitteet ja henkilöstö, jotka yhdessä tukevat yrityksen pitkän aikavälin strategiaa. Kapasiteettitasolla on suuri vaikutus yrityksen toimitusvarmuuteen, kustannusrakenteeseen, varastointipolitiikkaan, johtoon ja henkilöstövaatimuksiin. (Jacobs & Chase 2017, s. 96–97)

1.1 Työn rajaus ja tavoite

Tämä kandidaatintyö on toteutettu Okmetic Oy:n toimeksiantona. Kandidaatintyössä käsitellään kysynnän ennustamisen kvantitatiivisia ja kvalitatiivisia menetelmiä. Työssä tutkitaan kirjallisuuteen perustuen kysynnän ennustamisen menetelmiä, sekä miten kysynnän ennustamista on harjoitettu puolijohdeteollisuudessa. Työssä arvioidaan Okmeticin kysynnän ennustamisen ja kapasiteetin hallinnan nykytilaa, sekä niiden kehitysmahdollisuuksia. Kapasiteetin hallinnan kehitysmahdollisuuksia tarkastellaan pitkällä aikavälillä. Tavoitteena on löytää vähintään yksi kysynnän ennustamisen menetelmä, jota Okmeticissa voidaan hyödyntää.

1.2 Työn rakenne

Tämä kandidaatintyö on eroteltu teoria- ja empiriaosaan. Teoriaa käsittelevässä osiossa tehdään yleiskatsaus kysynnän ennustamiseen, sekä eritellään kvalitatiivisia ja kvantitatiivisia ennustamismenetelmiä. Työssä käydään myös läpi tekoälyn hyödyntämisen mahdollisuuksia kysynnän ennustamisessa, ja tuodaan esille kysynnän ennustamiseen liittyviä haasteita. Tämän jälkeen verrataan teoreettisia kysynnän ennustamismenetelmiä Okmeticin nykytilaan, sekä valitaan, mitä menetelmiä voitaisiin ottaa käyttöön kysynnän ennustamisen tueksi. Lopuksi työssä arvioidaan, miten kapasiteetin hallinta kehittyisi, jos kysynnän ennusteet olisivat tarkempia. Työ on toteutettu kirjallisuuskatsauksena, mutta osa empiriaosan tiedoista, jotka käsittelevät Okmeticin asioita, on saatu haastattelemalla Okmeticin henkilöstöä sekä Okmeticin sisäisistä raporteista.

2 KYSYNNÄN ENNUSTAMINEN

Yrityksen merkittävin tarkoitus on tyydyttää asiakkaiden tarpeet. Yrityksillä on monia syitä toteuttaa kysynnän ennustamista, mutta se on välttämätöntä, jos halutaan suunnitella lyhyen, keskipitkän ja pitkän aikavälin toimintoja. Lyhyen aikavälin (0–4 kuukautta) ennusteella voidaan esimerkiksi aikatauluttaa tuotantojärjestys. Keskipitkän aikavälin (1–3 vuotta) ennusteella voidaan arvioida kokonaiskysyntää kapasiteetin hallinnan ja tuotannonsuunnittelun tueksi. Pitkän aikavälin (2–10 vuotta) kysynnän ennuste auttaa yrityksen johtoa strategisten liiketoimintojen suunnittelussa. (Arnold et al. 2008, s. 216–217)

Myynnin ennustamisen hallinnassa on kyse ennustamisfunktiosta organisaation sisällä. Vaikka käsitellään myynnin ennustamista, todellisuudessa on tärkeää pyrkiä ennustamaan asiakkaiden kysyntää. (Mentzer & Moon 2005, s. 8) Myynnin ja kysynnän ero on siinä, että kysyntä osoittaa tuotteen tai palvelun tarpeen, ja myynti osoittaa todellisen menekin. Toisinaan kysyntää ei pystytä tyydyttämään, jolloin myynti onkin pienempää kuin kysyntä. (Arnold et al. 2008, s. 218)

Buffan ja Sarinin (1987, s. 55) mukaan ennustamismenetelmät voidaan jakaa karkeasti kolmeen eri kategoriaan:

1) Aikasarjamallit
2) Kausaalimallit
3) Kvalitatiiviset menetelmät

Aikasarjamallit ja kausaalimallit kuuluvat kvantitatiivisiin ennustamismenetelmiin (Moon 2018, s. 88). Kuvassa 1 on esitelty ennustamismenetelmien kategoriat. Aikasarjamallit ja kausaalimallit on luokiteltu kvantitatiivisiksi, sillä ne perustuvat laskettavassa muodossa olevaan tilastolliseen dataan.

Kuva 1. Ennustamismenetelmien jaottelu.

Ennustamismenetelmän tarkkuus, kustannukset, yksinkertaisuus ja yrityksen operatiivisen toiminnan suunnittelun tarpeet ovat asioita, jotka vaikuttavat menetelmän valintaan. Joissakin tilanteissa voi olla järkevää hyödyntää useampaa kuin yhtä ennustamismenetelmää. (Buffa & Sarin 1987, s. 84)

2.1 Kvalitatiiviset ennustamismenetelmät

Kvalitatiiviset ennusteet perustuvat mielipiteisiin, markkinatietoon ja ammattilaisten intuitioon. Jos yrityksen tuotteiden kysyntää ennustetaan historialliseen dataan perustuvalla kvantitatiivisella ennustemallilla, ja uskotaan, ettei ennustemalli ennusta sellaisenaan tulevaisuutta, voisivat kvalitatiiviset ennustamistekniikat olla tehokas tapa parantaa ennustetarkkuutta. Kvalitatiivisia ennustamismenetelmiä voidaan myös käyttää hyväksi, kun ennustetaan uusien tuotteiden kysyntää, joista ei vielä ole historiallista dataa. (Mentzer & Moon 2005, s. 144–147) Tällaisessa tilanteessa asiantuntijoiden tieto samankaltaisista tuotteista, asiakkaiden kulutustottumuksista ja markkinointikanavasta voi edesauttaa kysynnän ennustamisen onnistumista (Jacobs & Chase 2017, s. 73).

2.1.1 Delfoi -menetelmä

Olaf Helmerin kehittämä Delfoi -menetelmä perustuu asiantuntijoiden mielipiteisiin. Yksinkertaisimmillaan menetelmä toimii siten, että joukko asiantuntijoita vastaa tiettyyn

aihepiiriin liittyviin kysymyksiin itsenäisesti. Yleensä vastaus annetaan numeerisessa muodossa. Asiantuntijat eivät tiedä toistensa vastauksia, mutta saavat kuulla menetelmän valvojalta vastausten antamisen jälkeen vastausten kvartaalijakauman. Tämän jälkeen asiantuntijoita pyydetään harkitsemaan uudelleen omaa vastaustaan. Ne asiantuntijat, jotka vastasivat ylä- ja alakvartaalin välisen alueen ulkopuolelle, joutuvat perustelemaan oman vastauksensa. Tämän jälkeen menetelmän valvoja kerää vastaukset jälleen yhteen ja luo vastauksista taas kvartaalijakauman. Kvartaalijakauma näytetään asiantuntijoille, ja tällä kertaa asiantuntijoita, jotka ovat vastanneet jälleen ylä- ja alakvartaalin välisen alueen ulkopuolelle, pyydetään perustelemaan, miksi vastapuolen kvartaalin ulkopuolella olevat vastaukset ovat vääriä. Prosessia jatketaan edellä mainitulla logiikalla niin monta kierrosta, että asiantuntijat pääsevät yhteisymmärrykseen ja menetelmän lopputulosta voidaan hyödyntää tulevaisuuden suunnittelussa. Delfoi -menetelmä on työvoimavaltaista, aikaa vievää ja kallista. Näin ollen Delfoi -menetelmä onkin käytännöllinen vain pitkän aikavälin ennustamisessa. (Fitzsimmons & Fitzsimmons 2011, s. 455)

2.1.2 Markkina-analyysi

Markkina-analyysissä arvioidaan kuluttajien ostokäyttäytymistä. Ostokäyttäytymiseen liittyvä data on hyvin arvokasta, kun ennustetaan koko markkinan kysyntää. Markkina-analyysissä hyödynnettäviä tutkimusmenetelmiä ovat kyselylomakkeet, kuluttajapaneelit ja tuotteiden testaus. Markkina-analyysiä hyödynnetään ensisijaisesti uusien tuotteiden lanseerauksessa. (Buffa & Sarin 1987, s. 82) Markkinadatan avulla voidaan selvittää kuluttajien mielenkiintoa hankintoihin ja täysin uusia tuotteita kohtaan. Toimitusketjun alkupäässä oleva valmistaja pystyy hyödyntämään markkina-analyysiä arvioidessaan jakelijoiden myynnin ennusteiden luotettavuutta. Yritys voi esimerkiksi haastatella joukon kotitalouksia niiden kulutustottumuksista, tai taloustieteilijöitä toimialan taloudellisesta tilanteesta. (Mentzer & Moon 2005, s. 163)

2.1.3 Sales Force Composite -menetelmä

Sales Force Composite -menetelmä hyödyntää myyntihenkilöiden ja myynnin johdon tietotaitoa sekä kokemusta kysynnän ennusteiden tuottamisessa. Myyntihenkilöt tuottavat oman vastuualueensa ennusteet. Vastuualueina voivat toimia muun muassa yksi tai useampi maanosa, tuote tai asiakas. Vuonna 2011 toteutetun tutkimuksen mukaan, yritykset odottavat myyjien kysynnän ennusteilta korkeaa tarkkuutta, mutta eivät kuitenkaan tarjoa myyjille riittävästi resursseja ennusteiden suorittamista varten. *Sales Force Composite* -menetelmällä on kuitenkin hyviäkin puolia. Ennusteen tekee se henkilö, joka tietää eniten ennustettavasta asiakkaasta, eli myyjä. Myyjä pystyy vaikuttamaan suoraan asiakaskohtaiseen myyntimäärään ja selvittämään syitä ennustevirheen suuruudesta asiakkaan kanssa. (Moon 2018, s. 125–126)

Yritykset ovat kuitenkin usein turhautuneita myyjien tekemien ennusteiden laatuun, vaikka myyjät tuovat tärkeää informaatiota ennustamisprosessiin. Myyjät monesti kokevat työnsä olevan vain myyntiä, vaikka todellisuudessa heidän työnkuvaansa kuuluu kolme asiaa: tuotteiden tai palveluiden myynti, asiakkuussuhteiden kehittäminen ja ylläpito, sekä markkinatiedon tarjoaminen yritykselle. Kysynnän ennustaminen on yksi tärkeimmistä asioista markkinatiedon tarjoamiseen liittyen. Yritykset voivat parantaa ennustamisprosessin tehokkuutta tekemällä ennustamisesta osan myyjien virallista työnkuvaa. Ennustamisen tulisi olla osa myyjien tehokkuuden arviointia ja se tulisi myös huomioida tulospalkkioissa. Lisäksi myyjiä tulisi kouluttaa kvantitatiivisiin ennustamismenetelmiin ja tuoda esille sitä, mihin yrityksen toimintoihin ennusteita hyödynnetään. Myyjille tulisi myös opettaa, kuinka asiakkaiden kanssa keskustellaan ennustamisesta, jotta asiakkaiden tuottamat ennusteet omasta kulutuksestaan olisivat mahdollisimman tarkkoja. Tarkat ennusteet olisivat kaikkien toimitusketjussa toimivien sidosryhmien etujen mukaista. (Moon 2018, s. 126–128)

2.2 Kvantitatiiviset ennustamismenetelmät

Kvantitatiivinen ennustaminen pohjautuu matemaattisiin malleihin. Kvantitatiiviset ennustamismenetelmät voidaan jaotella aikasarjamalleihin ja kausaalimalleihin. (Fitzsimmons & Fitzsimmons 2011, s. 47) Aikasarjamalleissa ennuste pyritään luomaan toteutuneen historiatiedon pohjalta. Kausaalimalleissa pyritään löytämään muita selittäviä tekijöitä, kuten

hinta, markkinointi ja myynnin edistäminen, jotka vaikuttavat myynnin muutokseen. (Chase 1997, s. 22)

2.2.1 Aikasarjamallit

Kaikki aikasarjaan pohjautuvat tekniikat ovat endogeenisia – niissä verrataan historiatietoa toteutuneesta myynnistä ja muodostetaan siitä malleja. Jos malli, joka peilaa myynnin historiaan, toimii myös tulevaisuuden osalta, niin sitä voidaan käyttää sellaisenaan. Kaikki aikasarjamallit hyödyntävät yhtä tai useampaa seuraavista komponenteista: Taso (*Level*), trendi (*Trend*), kausivaihtelu (*Seasonality*) ja satunnaisvaihtelu (*Noise*) (Kuva 2). Aikasarja-analyysit poikkeavat regressioanalyyseistä siten, että regressioanalyyseissä tarkastellaan ulkoisten asioiden verrannollisuutta myyntiin, kun taas aikasarja-analyyseissä tarkastellaan yrityksen myyntihistoriaa tietyllä ajanjaksolla. (Mentzer & Moon 2005, s. 74)

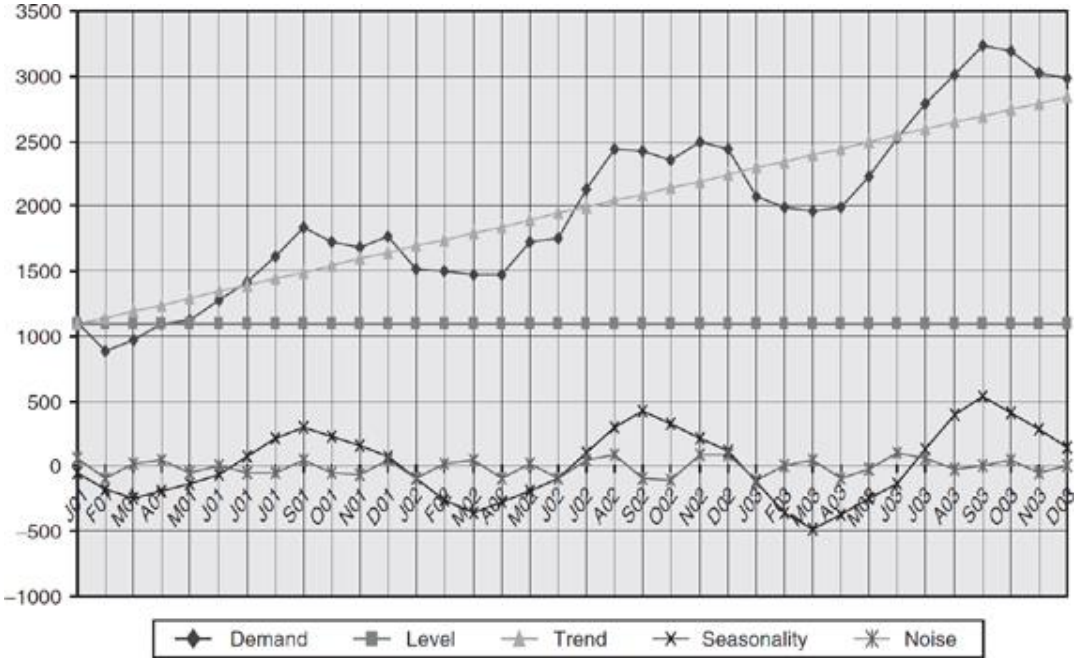

Kuva 2. Aikasarjamallien komponentit (Mentzer & Moon 2005, s. 75)

Liukuva keskiarvo toimii kysynnän ennustamismenetelmänä hyvin tilanteessa, jossa tuotteen kysyntä ei kasva tai laske nopeasti, eikä kysynnällä ole kausivaihtelua. Liukuvan keskiarvon menetelmä poistaa kysynnästä satunnaisvaihtelun. Menetelmä on hyvin yksinkertainen ja se ottaa huomioon valitun määrän ajanjaksoja, joiden kysynnän keskiarvolla ennustetaan tulevan

ajanjakson kysynnän määrä. (Jacobs & Chase 2017, s. 50) Liukuva keskiarvo on esitelty kaavassa 1 (Moon 2018, s. 95).

$$F_{t+1} = \frac{D_t + D_{t-1} + D_{t-2} + \cdots + D_{t-[N-1]}}{N} \quad (1)$$

jossa: F_{t+1} = Ennuste ajanjaksolle *t+1*

D_{t-1} = Toteutunut kysyntä ajanjaksolla *t-1*

N = Ajanjaksojen määrä

Liukuvan keskiarvon menetelmässä ennusteen tuottaja voi valita ajanjaksojen määrän, joiden perusteella tehdään seuraavan ajanjakson ennuste. Näin ollen vain relevantit ajanjaksot voidaan ottaa huomioon. (Moon 2018, s. 95)

Eksponentiaalisen tasoituksen ennustamismenetelmä soveltuu parhaiten tilanteisiin, joissa ennustamishorisontti on esimerkiksi viikko tai kuukausi, kysynnän syy-seuraussuhteita ei tunneta ja ei haluta käyttää kovin paljoa resursseja ennustamiseen. Eksponentiaalinen tasoitus on yksinkertaisimmassa muodossa silloin, kun kysyntädatassa ei ole trendin tai kausivaihtelun komponentteja. Todellinen kysyntä vaihtelee keskimääräisen kysynnän tason ylä- tai alapuolella. (Buffa & Sarin 1987, s. 58) Eksponentiaalinen tasoitus toimii samoin kuin liukuva keskiarvo, mutta se ottaa huomioon viimeisimpien ajanjaksojen kysynnän suuremmalla painoarvolla. Painoarvo laskee eksponentiaalisesti, mitä vanhempia ajanjaksoja ennustamisessa otetaan tarkasteluun. Eksponentiaalinen tasoitus on esitelty kaavassa 2. (Mentzer & Moon 2005, s. 85)

$$F_{t+1} = \alpha S_t + (1 - \alpha) F_t \quad (2)$$

jossa: F_{t+1} = Eksponentiaalisesti tasoitettu ennuste ajanjaksolle *t+1*

α = Tasoitusvakio, $0 < \alpha < 1$

F_t = Eksponentiaalisesti tasoitettu ennuste ajanjaksolla *t*

S_t = Todellinen kysyntä ajanjaksolla *t*

Kun α on asetettu esimerkiksi 0.1, tällöin viimeisimmällä toteutuneella kysynnällä on hyvin pieni painoarvo, kun taas edellisiin ajanjaksoihin perustuvan ennusteen painoarvo on suurempi. Mitä suurempi α valitaan, sitä suurempi painoarvo on edellisen ajanjakson toteutuneella kysynnällä. Nykyiselle ajanjaksolle tehty ennuste F_t sisältää eksponentiaalisen painon jakautumisen pohjautuen edellisten aikajaksojen kysyntään, joka tekee ennustamismenetelmän luonteesta eksponentiaalisen. (Moon 2018, s. 98)

2.2.2 Kausaalimallit

Kausaalimallit ovat kvantitatiivisia ennustamismalleja, joilla pyritään löytämään ulkoisia muuttujia, jotka vaikuttavat yrityksen tuotteiden kysyntään. Yksinkertaistetusti kausaalimallien toimintaperiaate on se, että verrataan, korreloiko tuotteen tai tuoteryhmän kysyntä jonkin ulkoisen asian kanssa. Esimerkiksi, jos yritys myy auton renkaita, voidaan tutkia, onko myynti verrannollinen polttoaineen kulutuksen kanssa. Kausaalimallien muuttujat voivat liittyä suuriin taloudellisiin asioihin, kuten esimerkiksi rakennusurakoiden myöntämismäärään, autojen valmistusmäärään tai bruttokansantuotteeseen. (Arnold et al. 2008, s. 223) Toisaalta muuttujia voivat olla myös esimerkiksi tuotteen laatu, tuotteen hinta tai logistiikkapalveluiden laatu (Mentzer & Moon 2005, s. 20). Käytetyimpiä kausaalimalleja ovat regressioanalyysi, moninkertainen regressioanalyysi ja ekonometrinen malli (Chase 1997, s. 28).

Regressioanalyysi on mahdollisesti yksi tarkimmista ennustamismalleista, mutta se vaatii paljon dataa. Suuri datan tarve hidastaa regressioanalyysin reagointinopeutta muuttuviin olosuhteisiin. Regressioanalyysi onkin hyödyllinen yli kuuden kuukauden aikahorisontin ennustamisessa. (Mentzer & Moon 2005, s. 20) Regressioanalyysi tarkastelee funktionaalisia riippuvuussuhteita kahden tai useamman korreloivan muuttujan välillä. Menetelmää hyödynnetään siten, että tiedossa olevalla muuttujalla pyritään saamaan vastaus toiseen muuttujaan, jota ei tiedetä. Ennen menetelmän hyödyntämistä täytyy kuitenkin selvittää, korreloiko data lineaarisesti muuttujien välillä. (Jacobs & Chase 2017, s. 57) Lineaarinen regressioanalyysi kysynnän ennustamisessa on esitelty kaavassa 3. (Buffa & Sarin 1987, s. 73–74)

$$\hat{Y} = a + bX \tag{3}$$

jossa: $\hat{Y}$ = Riippuvan muuttujan ennustettava arvo

a = Vakiotermi

b = Regressioyhtälön kulmakerroin

X = Riippumattoman muuttujan havaittu arvo

Regressioanalyysin ensimmäinen vaihe on muodostaa datasta hajontakaavio (Kuva 3). Pienimmän neliösumman menetelmällä saadaan liitettyä suora hajontakaavioon (Kuva 4). Tämä menetelmä minimoi neliöiden summan pystysuuntaisista poikkeamista. Menetelmässä piirretyn suoran positiiviset poikkeamat hajontakaavion yksittäisten pisteiden vertikaalisista arvoista ovat yhtä suuret kuin negatiiviset poikkeamat. Pienimmän neliösumman menetelmällä regressiosuoran arvot *a* ja *b* voidaan laskea datasta kaavoilla 4 ja 5. Kaavojen mukaan, arvot *a* ja *b* lasketaan siten, että $\sum(Y - \hat{Y})^2$ on mahdollisimman pieni. (Buffa & Sarin 1987, s. 72–75)

$$b = \frac{\sum(XY) - n\bar{X}\bar{Y}}{\sum(X^2) - \bar{X}^2} \tag{4}$$

$$a = \bar{Y} - b\bar{X} \tag{5}$$

jossa: X = Muuttujan X arvo

Y = Muuttujan Y arvo

$\bar{X} = \frac{\sum X}{n}$ = Muuttujien X aritmeettinen keskiarvo

$\bar{Y} = \frac{\sum Y}{n}$ = Muuttujien Y aritmeettinen keskiarvo

n = Havaintojen lukumäärä

Kuvissa 3 ja 4 on simuloitu kuvitteellisen yrityksen ja toimialan kysyntää seuraavilla oletuksilla: yrityksen kysyntä on noin 10 % toimialan kokonaiskysynnästä, ja toimialan kokonaiskysyntä kasvaa joka kvartaali keskimäärin 10 % verrattuna edelliseen kvartaaliin.

Kuvaajissa havaintoja, eli kvartaaleja, on 23 kappaletta, näin ollen n = 23. Niin yrityksen kuin myös toimialan kysynnöissä on toisistaan riippumaton, noin 8 % satunnainen hajonta, jotta hypoteettinen tilanne vaikuttaisi realistiselta.

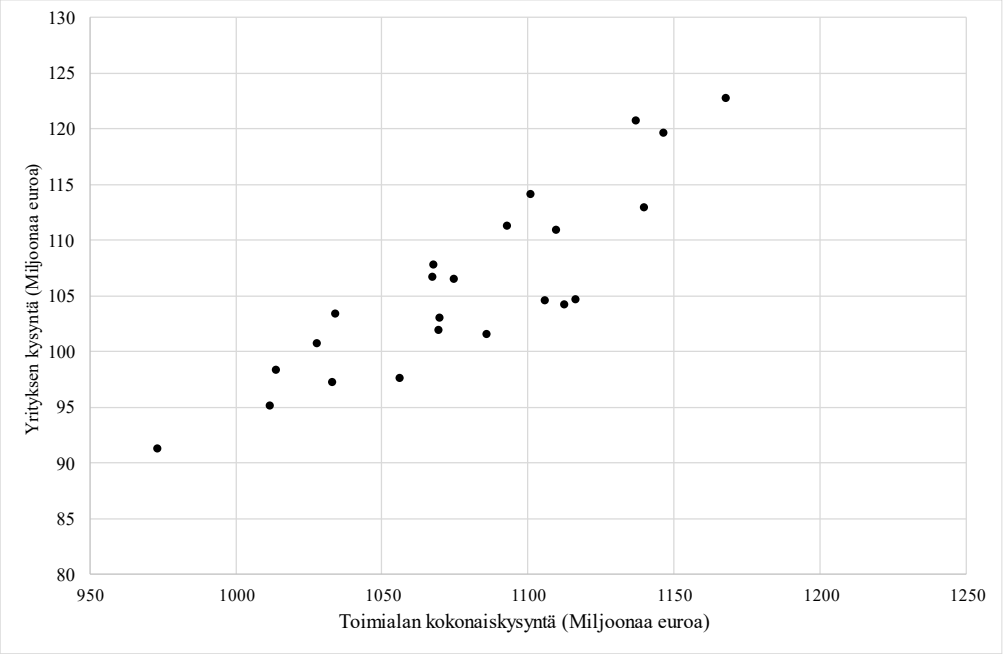

Kuva 3. Kuvitteellisen kysynnän hajontakaavio.

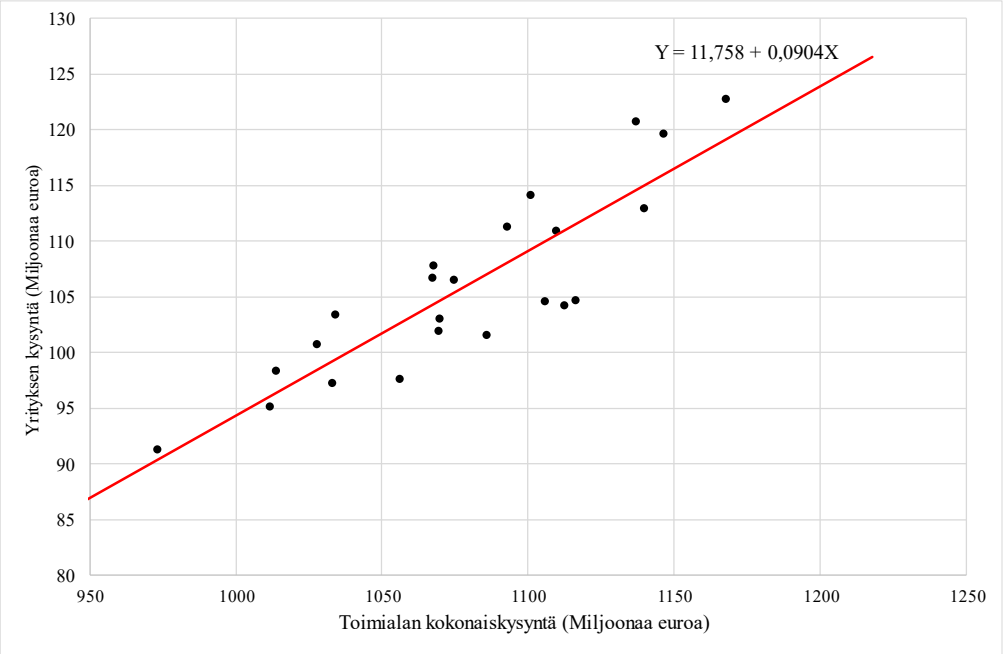

Kuva 4. Kuvitteellisen kysynnän hajontakaavioon piirretty regressiosuora.

2.3 Yhdistelmämenetelmät

Joissain tilanteissa ennustamismenetelmien yhdistäminen on kannattavampaa kuin yhden menetelmän käyttö (Buffa & Sarin 1987, s. 55). Yhdistelemällä aikasarjamenetelmiä ja subjektiiviseen arvioon perustuvia menetelmiä saadaan parannettua ennustetarkkuutta, jos asiantuntijoilla on hyvä toimialan tuntemus ja kysynnässä näkyy voimakas trendi. (Kerkkänen 2010, s. 27)

Neljä kysynnän ennustamisen yhdistelmämenetelmää ovat oikaisu (*Correcting*), yhdistely (*Combining*), subjektiiviseen arvioon perustuva säätö (*Judgemental adjustment*) ja subjektiivista arviota ennustemallissa hyödyntävä malli (*Judgement as input to model building*). Oikaisu (*Correcting*) on menetelmä, jossa hyödynnetään regressiota. Tämän avulla tunnistetaan ennustevirheitä subjektiivisissa ennusteissa. Yhdistely (*Combining*) on menetelmä, jossa ennuste saadaan laskemalla normaali- tai painotettu keskiarvo yksittäisistä subjektiivisista ja tilastollisista ennusteista. Subjektiiviseen arvioon perustuva säätö (*Judgemental adjustment*) on menetelmä, jossa matemaattisesti luotua ennustetta säädetään asianyhteyteen liittyvien tietojen mukaan. Myös subjektiivista arviota voidaan hyödyntää ennustemallin rakentamisessa (*Judgement as input to model building*). Edellä mainitussa menetelmässä tehdään subjektiivinen päätös muuttujista, mallin rakenteesta sekä parametreistä. (Kerkkänen 2010, s. 27–28)

2.4 Tekoäly kysynnän ennustamisen työkaluna

Ajan saatossa kysynnän ennustamisen tekniikoiden ja niiden parametrien määrä lisääntyy, joka tuottaa haasteita oikean menetelmän valintaan. Yksi ratkaisu ongelmaan on hyödyntää niin sanottuja universaaleja approksimointialgoritmeja (*Universal approximators*). Ne voivat tuottaa likiarvoja mihin tahansa funktioon mielivaltaisesti. Nämä algoritmit pystyvät oppimaan minkä tahansa funktion, menneen ja tulevan datan välillä. Näin ollen algoritmit pystyvät oppimaan ja hyödyntämään tehokkaasti myös perinteisiä ennustamistekniikoita. Koneoppimistekniikat, kuten esimerkiksi keinotekoiset neuroverkot (*Artificial neural networks*) ja tukivektorit (*Support vector machines*), ovat universaaleja

approksimointialgoritmeja ja näin ollen voivat oppia minkä tahansa funktion. (Carbonneau et al. 2007, s. 42–43)

Tekoälyä voidaan käyttää ennustamisen tukena hyödyntämällä muun muassa neuroverkkoja ja tukivektoreita. Neuroverkot toimivat siten, että jokainen elementti, eli neuroni on järjestetty tasoihin, joista neuronin informaation lähtösignaali siirtyy seuraavan tason kaikkiin neuroneihin (Kuva 5). Neuronit aktivoituvat vain yhteen suuntaan, eli informaatio ei kulje taaksepäin. Mitä enemmän välikerroksia neuroverkossa on, sitä enemmän neuroverkolla on laskentatehoa. Jotta neuroverkot tuottavat toivottuja loppuarvoja syötetystä datasta, niitä täytyy treenata. Neuroverkkojen treenaaminen tapahtuu syöttö- ja ulostulopareina. Täten neuroverkot pystyvät löytämään ja oppimaan syy-seuraussuhteita halutun aihealueen historiallisesta datasta. (Carbonneau et al. 2008, s. 1143–1144)

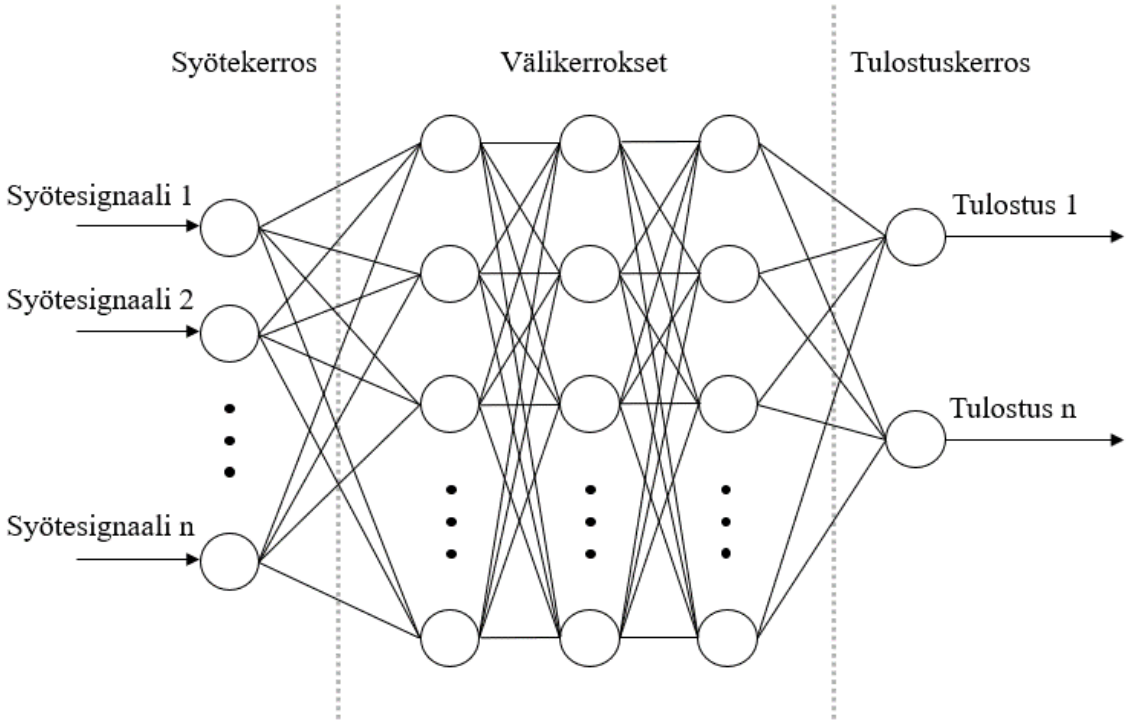

Kuva 5. Neuroverkon rakenne ja informaation kulku. (Bre et al. 2017, s. 4)

2.5 Kysynnän ennustamisen haasteet

Kvalitatiivisissa kysynnän ennustamismenetelmissä on myös negatiivisia puolia. Henkilö, joka tekee ennusteen, saattaa tehdä sen mielivaltaisesti jättämällä huomioimatta tärkeää informaatiota. Tällöin ennustetarkkuus heikkenee. Lisäksi kvalitatiiviset kysynnän ennustamismenetelmät ovat kalliita toteuttaa, koska ne vaativat paljon hallinnointia ja analysointia, joka on aikaa vievää. (Mentzer & Moon 2005, s. 147)

Monissa organisaatioissa sekoitetaan kysynnän ennustaminen ja myyntitavoitteet, kun kysynnän ennustamista toteuttavat myyjät. Jos myyjät ovat optimistisia tulevasta myyntikaudesta, he saattavat asettaa ennusteen ylöspäin suuntautuvasti. Toisaalta myyjät voivat myös asettaa ennusteen menemään mielivaltaisesti alaspäin, jolloin myyjä näyttää tehokkaammalta työntekijältä yrityksen näkökulmasta, kun lopputuloksena onkin ennustettua korkeammat myyntiluvut. (Mentzer & Moon 2005, s. 148)

Poliittiset tekijät organisaatioiden välillä voivat aiheuttaa puolueellisuutta myynnin ennustamisessa. Poliittiset paineet realisoituvat yleensä valmistajan ja jakelijan toimitusketjun välissä. Realistisen kysynnän ennusteen sijaan, jakelija voi toimittaa toimittajalle ennusteen, joka on todellista kulutusennustetta suurempi. Näin jakelija voi saada käyttöönsä ilmaista varastotilaa tavarantoimittajalta, koska toimittaja varautuu siihen, että jakelijan kysyntä olisi suurempaa. Jos taas varastotilaa ei ole tavarantoimittajalla vaan jakelijalla, varsinkin uusien tuotteiden kohdalla jakelijan toimittamat ennusteet voivat olla todellisia kulutusennusteita pienempiä, jolloin jakelija ei joudu varautumaan niin suuriin varastointikustannuksiin. (Mentzer & Moon 2005, s. 149)

Piiskavaikutus (*Bullwhip effect*) tarkoittaa ilmiötä, jossa tilausmäärän vaihtelu kasvattaa toimitusketjun alkupäässä olevien toimijoiden, eli tavarantoimittajien, tuotantomäärien vaihtelua. Se on merkittävä tekijä, kun tuotannon vaihtelun kustannukset ylittävät varastoinnin kustannukset. Piiskavaikutuksen kustannukset tulevat esiin esimerkiksi koneiden hankinta- ja suljentakustannuksissa, ylityökustannuksissa, rekrytointi- ja irtisanomiskustannuksissa, ennustamis- ja aikataulutuskustannuksissa sekä huonosta kommunikaatiosta tavarantoimittajien ja asiakkaiden välillä aiheutuvista kustannuksista. Piiskavaikutusta voidaan

lieventää jakamalla informaatiota toimijoiden välillä. Varastotasot, myyntimäärät, myynnin ennusteet, tilauskanta ja tuotantoaikataulu ovat tärkeää informaatiota, jota voidaan jakaa tavarantoimittajalle tai yrityksen omille asiakkaille. Informaation jakaminen on tärkeää tilanteissa, joissa kysyntä korreloi voimakkaasti, vaihtelee voimakkaasti tai tuotannon läpimenoaika on pitkä. (Wang & Disney 2016, s. 691–696) Kuvassa 6 on havainnollistettu, kuinka kysynnän muutos vaikuttaa piiskan omaisesti kasvavasti kysyntään, kun siirrytään toimitusketjussa kohti alkupäätä.

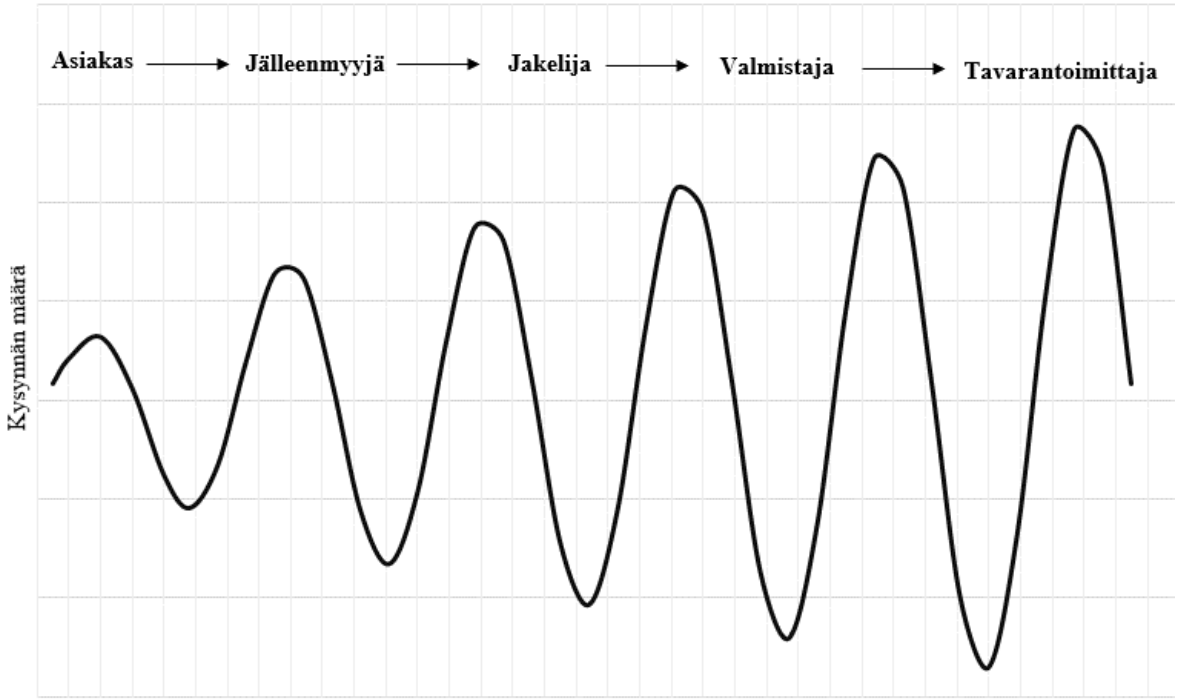

Kuva 6. Piiskavaikutus.

2.6 Ennustetarkkuus

Yksi myynnin ennustamisfunktion onnistumisen mittareista on ennustetarkkuus. Kaksi muuta ovat ennusteen kustannukset sekä asiakastyytyväisyys. Myynnin ennusteiden ollessa tarkkoja, yritys voi suunnitella omaa toimintaansa suuremmalla varmuudella. Kuitenkin saattaa olla haastavaa määrittää arvioitua ennustevirheen suuruutta edes jälkikäteen. Se johtuu siitä, että lukemattomia tarkkuustilastoja on saatavilla kaikille ennustamismenetelmille. (Mentzer & Moon 2005, s. 44–45)

Ennustetarkkuutta mitataan useimmiten laskemalla ennustevirheen prosenttiluvun keskiarvo tarkasteltavalle ajanjaksolle. Ennustevirheen prosenttiluvut on kuitenkin hyvä laittaa itseisarvoon, jotta yli- ja alimenevät ennustevirheet eivät kumoa toisiaan. Itseisarvoinen ennustevirheprosentin keskiarvo *MAPE* (*Mean Absolute Percent Error*) on esitelty kaavassa 7. Menetelmässä taulukoidaan ennustettu kysyntä, toteutunut kysyntä, ennustevirheprosentti ja itseisarvoinen ennustevirheprosentti. (Moon 2018, s. 160–161) Kaavassa 7 tarvittava ajanjakson prosentuaalinen ennustevirhe *PE* (*Percent Error*) on laskettu kaavassa 6 (Moon 2018, s. 152).

$$PE = \frac{Ennustettu\ kysyntä - Toteutunut\ kysyntä}{Toteutunut\ kysyntä} * 100 \qquad (6)$$

$$MAPE = \frac{\sum |PE|}{N} \qquad (7)$$

jossa: $|PE| =$ Ajanjakson itseisarvoinen ennustevirheprosentti

$N =$ Ajanjaksojen määrä, joilta ennustevirhettä on seurattu

Itseisarvoinen ennustevirheprosentin keskiarvo *MAPE* on hyvä mittari, kun halutaan seurata kysynnän ennustamisen tarkkuuden onnistumista. Menetelmän avulla voidaan huomata helposti, jos ennustamisprosessin ennustetarkkuus alkaa heikentyä. *MAPE* on myös hyvä työkalu seuraamaan yksilöiden ennustetarkkuutta. Työkalua hyödyntäessä täytyy kuitenkin osata valita sopiva määrä tarkasteltavia ajanjaksoja. Jos ajanjaksoja on liikaa, viimeisimpien ajanjaksojen tulokset eivät välttämättä vaikuta lopputulokseen riittävästi. Työkalussa kannattaakin hyödyntää esimerkiksi kiinteää historiaan peilaavaa 12 kuukauden juoksevaa aikaa. (Moon 2018, s. 160–167)

2.7 Kysynnän ennustaminen puolijohdeteollisuudessa

Puolijohdetoimiala on pääomavaltaista, ja kapasiteetin laajentaminen on hidas prosessi. Toimialan yritysten strategiset päätökset pitävät sisällään toisiinsa liittyviä elementtejä kuten hinnoittelupäätökset, kysynnän ennusteet, kapasiteetin suunnittelun, investoinnit ja kustannusrakenteen. Näin ollen puolijohdeteollisuuden yritysten täytyykin ennustaa

tulevaisuuden kysyntää, jotta tuotannon investointeja voidaan toteuttaa. (Chien et al. 2010, s. 496)

Yritykset pitävät varmuusvarastoja kysynnän vaihteluiden ja ennustevirheen vuoksi, koska piiskavaikutus tuo toimitusketjun alkupäähän vaikeasti ennustettavaa kysynnän vaihtelua. Puolijohdeteollisuuden parissa toimivien yritysten onkin äärimmäisen tärkeää luoda joustava ennustamisjärjestelmä, joka vastaa nopeasti piiskavaikutuksen tuomiin haasteisiin toimitusketjussa. Kuitenkin esimerkiksi lyhentynyt tuotteiden käyttöikä ja tuotevariaatiot kuluttajaelektroniikkatuotteissa luovat kysynnän vaihteluita ja tekevät kysynnän ennustamisesta haastavaa. Ennustevirhe aiheuttaa epätehokasta kapasiteetin hyödyntämistä, joka vaikuttaa lopulta yritysten kannattavuuteen. (Chien et al. 2010, s. 496)

Käytännössä monet toimialan yritykset ennustavat kysyntää aluekohtaisesti asiakkailta saatavilla ennusteilla, joita säädetään subjektiivisella alue- ja markkinatuntemuksella. Kuitenkin asiakkailta saatavilla ennusteilla on taipumus olla puolueellisia, koska asiakkaat haluavat lisätä toimitusvarmuutta. Lisäksi piiskavaikutus ajaa myös asiakkaat tuottamaan ylisuuria ennusteita. (Chien et al. 2010, s. 496)

Chien et al. (2010, s. 499) tutkii kysynnän ennustamisen kehittämistä puolijohdeteollisuudessa monisukupolvisen diffuusiomallin avulla (*Multi-generation diffusion model*). Diffuusiomalli on rakennettu *Norton* ja *Bass* mallien pohjalta. *Multi-generation diffusion model* -menetelmä tutkii viittä eri tekijää, jotka vaikuttavat kysyntään: kysynnän kausiluonteisuus, markkinan kasvunopeus, tuotteen hinta, asiakkaiden toistuvat ostot ja vaihtoehtoinen teknologia. Tekijät on valittu menetelmään kirjallisuuden, asiantuntijoiden mielipiteiden ja tilastojen perusteella. (Chien et al. 2010, s. 499) Menetelmän aikajänne on 36 kuukautta ja tarkastelujakso on yksi kvartaali, eli 3 kuukautta (Chien et al. 2010, s. 503). Yksinkertaistetusti malli toimii siten, että se pyrkii löytämään tekijöistä eri sukupolvien välisiä muutoksia. Kyseistä diffuusiomallia pystytään soveltamaan puolijohdeteollisuuden tuotteiden kysyntään hyvin, koska malli keskittyy olennaiseen tuoteinformaatioon. (Chien et al. 2010, s. 499)

3 KYSYNNÄN ENNUSTAMINEN OKMETIC OY:SSÄ

Puolijohdetoimiala kasvaa teknologian kehityksen myötä. Kysynnän ollessa vaihtelevaa ja globaalien kriisien lisätessä kysynnän vaihtelua, kysynnän ennusteiden tulee olla mahdollisimman tarkkoja. Ennustamisen kehittyessä pitkän aikavälin kapasiteettia voidaan optimoida oikein ajoitettujen rekrytointien ja investointien kautta. Näin puolijohdetoimialalla olevat yritykset pystyvät toimimaan mahdollisimman tehokkaasti.

3.1 Yritysesittely

Okmetic Oy on perustettu vuonna 1985 Nokia Oyj:n ja Outokumpu Oyj:n yhteisyritykseksi. Vuonna 2000 Okmetic listautui Helsingin pörssiin ja vuonna 2016 Okmetic siirtyi kiinalaisen NSIG:n omistukseen. Okmetic keskittyy puolijohdeteollisuuden niche-markkinoihin ja toimittaa piikiekkoja (Liite 1) pääasiassa mikrosysteemien (MEMS), anturien, RF-moduulien ja virtalähteiden valmistukseen. Markkina-alueina ovat Pohjois-Amerikka (25 %), Eurooppa (40 %) ja Aasia (35 %). Tuotanto tapahtuu Vantaalla ja sopimusvalmistajilla Aasiassa. Myyntiorganisaation toimipisteet sijaitsevat Suomessa, Yhdysvalloissa, Saksassa, Japanissa ja Kiinassa. Lisäksi Okmeticilla on myyntiagentteja Koreassa, Malesiassa, Singaporessa ja Taiwanissa. (Okmetic Oy 2021)

Sisäisten raporttien lisäksi, tietoa Okmeticin toiminnasta on saatu keväällä 2021 toteutettujen henkilöstön haastattelujen perusteella. Tällä hetkellä Okmeticin kysynnän ennusteen tekevät myyntihenkilöt asiakaskohtaisesti. Ennuste tehdään kuukausitasolla vuoden päähän, ja sitä tarkennetaan kaksi kertaa kuukaudessa. Okmetic tuottaa piikiekkoja vain tilauksesta, eikä suuria varastoja tehtaalla pidetä. Piikiekko voidaan valmistaa lukuisilla eri ominaisuuksilla, jotka vaikuttavat valmistus- ja toimitusaikoihin. Tilauksen valmistus kestää yleensä 4–10 viikkoa, mutta riippuen piikiekon valmistusprosessista, toimitus asiakkaalle voi tapahtua kahden päivän - kolmen kuukauden välisellä aikaikkunalla. Pisimmän ajan tuotannossa vie kuitenkin piikiteen kasvatus. Tilaukset tehdään aina asiakkaiden vaatimusten mukaisesti, joka aiheuttaa toimitusaikojen suuren vaihtelun.

3.2 Ennustamismenetelmien soveltuvuus Okmeticille

Okmeticin nykyinen toimintatapa on käyttökelpoinen jo sellaisenaan, koska toimialan trendit saattavat vaihdella nopeasti. Okmeticin toimiessa niche-markkinoilla, sen kysyntä saattaa vaihdella eri syklissä muuhun puolijohdeteollisuuteen verrattuna. Näin ollen myyjät toimivat eräänlaisina markkinoiden asiantuntijoina, sillä toimialatuntemus ja asiakkuussuhde ovat tärkeässä roolissa ennusteiden onnistumisessa. Myyntihenkilöillä ei kuitenkaan ole yhdenmukaista toimintatapaa ennusteiden tekemiselle, joten myyntihenkilöille olisi hyvä tarjota työkaluja, joilla ennustamismenetelmää voitaisiin yhdenmukaistaa.

Haastattelujen perusteella Okmeticin tämänhetkinen kysynnän ennustamismenetelmä noudattaa kappaleessa 2.1.3. esiteltyä *Sales Force Composite* -menetelmää. Myyntihenkilöt ennustavat omien asiakkaidensa kulutusta kaksi kertaa kuukaudessa, eli ennustaminen on suurelta osin myyjien työtä ja heidän vastuullaan. Lähtökohtaisesti myyntihenkilöt pyrkivät saamaan asiakkaalta ennusteen heidän kulutuksestaan, mutta jos asiakas ei pysty toimittamaan sitä, myyjä joutuu itse arvioimaan kulutusta. Kun asiakas toimittaa kulutusennusteen, myyntihenkilö arvioi subjektiivisesti, onko ennuste todenmukainen. Tarvittaessa myyjä keskustelee asiakkaan kanssa ennusteen todenmukaisuudesta, ja jos keskustelussa ilmenee ennustetarkkuutta alentavia asioita, hän pyytää asiakasta tarkentamaan ennustetta.

Myyntihenkilöt voisivat ottaa myynnin ennustamista tukeviksi työkaluiksi esimerkiksi kappaleessa 2.6 esitellyn *MAPE*:n, sekä kappaleessa 2.2.2 esitellyn regressioanalyysin. *MAPE*:lla voitaisiin seurata kysynnän ennusteiden ennustevirhettä asiakaskohtaisesti pitkällä aikavälillä. Menetelmään kuuluu itseisarvoisen ennustevirheen keskiarvon laskemisen lisäksi myös ennustevirhearvojen taulukointi, joten myyjillä olisi myös mahdollisuus seurata kvantitatiivisesti jokaisen asiakkaan tuottaman ennusteen ennustevirhettä. Ennen *MAPE*:n laskemista täytyy selvittää ennustevirheprosentti (*PE*). Ottamalla pelkän keskiarvon asiakkaiden tuottamien ennusteiden ennustevirheprosenteista, voitaisiin saada selville, tuottavatko asiakkaat systemaattisesti yli- tai alisuuria ennusteita. Regressioanalyysiä hyödyntämällä taas voitaisiin saada selville toimitusketjun loppupään tuotteiden kysyntää hyvissä ajoin. Näin voitaisiin huomata nopeasti kappaleessa 2.5 esitelty piiskavaikutus, joka

voi kasvattaa yrityksen kysyntää voimakkaasti, vaikka lopputuotteen kysyntä kasvaisi vain väliaikaisesti.

Regressioanalyysi olisi tehokasta rakentaa siten, että selvitettäisiin niiden toimitusketjun lopputuotteiden kysyntä, joiden valmistamiseen tarvitaan Okmeticin piikiekkoja. Haastatteluista Okmeticin asiantuntijoiden kanssa kävi kuitenkin ilmi, että asiakkaiden toiminta ei ole täysin läpinäkyvää, eli välttämättä ei tiedetä kaikkia lopputuotteita, joiden valmistuksessa käytetään Okmeticin piikiekkoja. Kuitenkin niille asiakkaille, joiden toimitusketjun myyntidataa pystytään selvittämään pitkälle, olisi hyvä rakentaa regressioanalyysi, varsinkin, jos asiakkaan kysyntä on suurta.

Kuvassa 7 on esitelty havainnollistus siitä, mitä dataa hyödyntämällä piiskavaikutusta ehkäisevä regressioanalyysi voitaisiin rakentaa. Analyysissä voisi verrata asiakkaan tuottaman kulutusennusteen ja lopputuotteiden myynnin määrää. Analyysistä voisi näin ollen saada selville piiskavaikutuksen suuruuden, sillä sen avulla pystyttäisiin seuraamaan toimitusketjun lopputuotteiden myynnin muutosta. Kun tietoa kerättäisiin ja mahdollista korrelaatiota syntyisi lopputuotteiden myynnin ja asiakkaiden tuottamien kulutusennusteiden kanssa, voitaisiin varautua kysynnän vaihteluihin paremmin. Analyysi voi myös auttaa selvittämään, onko myynnin kasvu tarkasteluhetkellä kestävällä pohjalla. Mikäli myyntiluvut, asiakkaiden tuottamat kulutusennusteet ja lopputuotteiden myyntimäärä näyttäisivät olevan pitkällä aikavälillä nousujohteisia, saattaisi olla tarve kasvattaa kapasiteettia. Kaiken kaikkiaan analyysi tuottaisi Okmeticille tietoa toimitusketjun kokonaiskysynnästä, ja sitä kautta keinon arvioida asiakkaiden ennusteiden todenmukaisuutta kvantitatiivisin perustein.

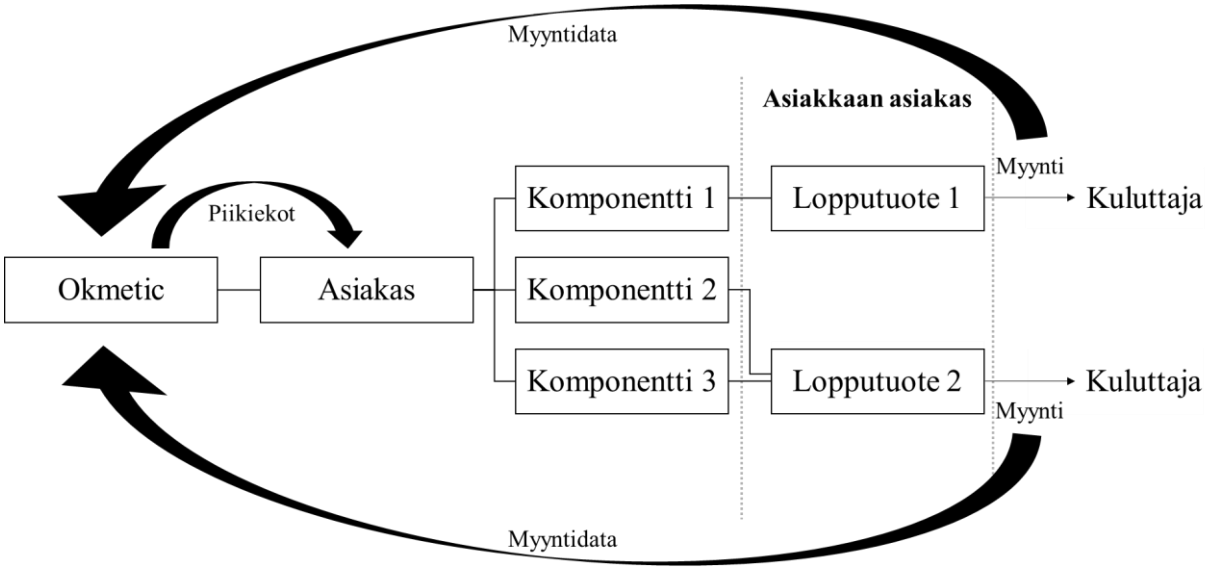

Kuva 7. Regressioanalyysiin saatava myyntidata optimaalisessa tilanteessa.

Kun myyjät ovat tuottaneet kysynnän ennusteet, myynnin johto tarkastelee vielä ennusteiden kokonaisuutta, ennen kuin tieto kysynnästä luovutetaan kapasiteetin suunnitteluun. Myynnin johto muokkaakin ennusteita yleensä aina niin, että kapasiteettia saadaan hyödynnettyä järkevästi. Näin ollen myynnin johdon tulisi myös olla tietoinen myynnin ennusteiden toteutustavoista. Kaikki työkalut, joita myyntihenkilöt hyödyntävät ennusteiden teossa, tulisi olla tiedossa myös myynnin johdolla.

Yksi hypoteettinen skenaario kysynnän ennustamisen kehittämiseksi voisi olla ennustamisen keskittäminen yhdelle henkilölle, jonka työ on ennustaa kysyntää kokonaisuudessaan. Näin ollen ennustaminen kaikkien asiakkaiden osalta toimisi johdonmukaisesti samoilla menetelmillä. Ennusteen tekijä voisi kuitenkin kerätä subjektiivista markkinatietoa myyntihenkilöiltä. Ennustamismenetelmäksi voisi kehittää koneoppimiseen perustuvan tekoälysovelluksen, joka ottaisi huomioon kysyntään liittyviä asioita, kuten trendi, kausivaihtelu, hinnan muutokset ja kilpailijoiden toiminta. Tällaisia ennustamispalveluja tarjoaa suomalaisista yrityksistä esimerkiksi RELEX Solutions. Koneoppiminen ei pelkästään tarkenna kysynnän ennusteiden tarkkuutta, vaan se myös automatisoi ison osan kysynnän ennustamiseen liittyvästä työstä ja pystyy prosessoimaan paljon suurempia datamääriä kuin mihin ihminen on kykenevä (RELEX Solutions 2021). Koska RELEX Solutionsin kysynnän ennustamiseen kehitetty koneoppimisalgoritmi on tarkoitettu vain vähittäiskaupoille (RELEX

Solutions 2021), se ei lähtökohtaisesti sovi Okmeticille sellaisenaan. Joitain elementtejä Okmeticin kysynnästä voisi kuitenkin olla mahdollista automatisoida vastaavanlaisilla tekniikoilla. Edellä mainittu radikaali muutos ennustamismenetelmässä tarkoittaisi todennäköisesti myös sitä, että kysynnän numeerinen ennustaminen ei olisi enää osa myyjien työnkuvaa.

3.3 Kapasiteetin hallinnan kehittäminen

Puolijohdetoimialalle ennustetaan kasvua, joka herättää alan yrityksissä mielenkiintoa kasvattaa tuotannon kapasiteettia. Tästä syystä uusien tuotantolaitteiden toimitusajat saattavat pidentyä, joka voi pahimmassa tapauksessa johtaa siihen, että juuri kun tuotantolaitteet saadaan käyttöön, kysynnän kasvu alkaa hiipua.

Okmetic hallitsee kysyntäpiikkejä siten, että kysynnän kasvaessa tuotantoa ostetaan alihankintana Aasiasta. Alihankintaa hyödyntäessä toimitusaikaan tulee aina vähintään viikko lisää, koska piikiteen kasvatus tapahtuu Vantaalla, ja piikiteen toimitus alihankkijalle kestää viikon. Jos Vantaan tuotannon kapasiteettia halutaan kasvattaa, on huomioitava, että laitteiden toimitusaika vaihtelee kuudesta kuukaudesta puoleentoista vuoteen, riippuen koneentoimittajien kysynnästä. Yleensä myös koneiden toimittajien kysyntä kasvaa puolijohdetoimialan kysynnän kasvaessa. Jos toimialan kysynnän kasvun nähdään ulottuvan pitkälle tulevaisuuteen, koneinvestointeja ja rekrytointeja on hyvä tehdä etukäteen, sillä henkilöstökapasiteetin lisäämisen vasteaika on noin kuusi kuukautta. Tämä johtuu siitä, että Okmeticin tuotteiden valmistus on tarkkuutta ja teknistä osaamista vaativaa työtä, joten koulutusaika on pitkä. Kapasiteettia voidaan kuitenkin lisätä tuotantoon vähitellen, eli koneita voidaan hankkia yksi kerrallaan.

Kysynnän ennusteiden tarkentuessa Okmetic voi suunnitella oman tuotantonsa pitkän aikavälin kapasiteetin vastaamaan Vantaalla valmistettavien tuotteiden kysyntää, sekä varata myös alihankintaverkostolta kapasiteettia yksinkertaisten tuotteiden valmistamiseen hyvissä ajoin etukäteen. Näin asiakkaille saataisiin toimitettua tuotteita oikea-aikaisesti, joka lisäisi asiakastyytyväisyyttä sekä tasoittaisi kysynnän vaihteluita.

4 JOHTOPÄÄTÖKSET

Kysynnän ennustaminen toimii liiketoiminnan perustana, sillä ilman tulevaisuuden kysyntää, yrityksellä ei ole tulevaisuutta. Yritysten on siksi tarpeellista kehittää kysynnän ennustamisen prosessia mahdollisuuksiensa mukaan. Toimintatapojen kehittäminen on kuitenkin kallista, joten yritysten täytyy arvioida, ovatko resurssit, joita ennustamisprosessin kehittäminen vaatii, käytetty järkevästi.

Mikään aikasarjamalli ei todennäköisesti toimi sellaisenaan Okmeticissa, koska muutokset kysynnässä voivat olla niin suuria, muun muassa piiskavaikutuksen johdosta, että ennustaminen ei voi pohjautua vain historialliseen tietoon. Aikasarjamallit eivät myöskään selvitä syitä kysynnän takana oleville ilmiöille. Myyjät ovat markkinaymmärryksen ja asiakkuussuhteiden vuoksi asianmukaisia henkilöitä ennusteiden tekemiseen. Mitä enemmän työkaluja myyjille tarjotaan subjektiivisten ennusteiden tekemisen tueksi, sitä enemmän myyjillä on mahdollisuus ymmärtää kysynnän takana olevia ilmiöitä. Okmeticissa myyntihenkilöt pystyisivät hyödyntämään regressioanalyysiä ja ennustetarkkuutta mittaavaa *MAPE*:a. Regressioanalyysin avulla kysynnästä voi selvittää syy-seuraussuhteita, jotka tuovat arvokasta informaatiota ennustamisprosessiin. Työkalujen käyttö tulisi olla yhdenmukaista, eli ne tulisi olla saatavilla kaikille myyntihenkilöille, ja olisi varmistuttava siitä, että niitä käytetään oikein. Myös myynnin johdolla tulisi olla ymmärrys työkalujen käyttötarkoituksesta sekä toimintamekanismeista, jotta myynnin ennusteiden kokonaisuutta tarkasteltaessa ymmärrettäisiin, kuinka ennusteet ovat syntyneet. Lisäksi myynnin johto voisi myös hyödyntää *MAPE*:a myyjien tuottamien ennusteiden tarkkuuden arvioimiseen. Pitkän aikavälin kysynnän ennusteiden ollessa tarkempia, Okmetic pystyisi optimoimaan kapasiteettitasoa suuremmalla varmuudella, sekä vastaamaan suuremmalla tarkkuudella asiakkaiden todelliseen kysyntään.

Jatkotutkimusideana voisi olla selvittää konkreettisella tasolla asiakkaiden tekemien ennusteiden ennustevirhe esimerkiksi *MAPE*:a ja *PE*:tä hyödyntäen. Ennustamisen kokonaisvirheen kannalta olisi tärkeää tietää, mitkä yritysasiakkaat ennustavat johdonmukaisesti edes hieman yli todellisen tarpeen. Tämän voisi selvittää laskemalla asiakaskohtaisesti niiden tuottamien ennusteiden ennustevirheprosenttien (*PE*) keskiarvon. Olisi suotavaa myös selvittää, kuinka työkalujen käyttö ja mahdollisesti ennustetarkkuuden

parantuminen vaikuttaisi asiakastyytyväisyyteen, ja kuinka palvelutasoa saataisiin konkreettisesti parannettua. Puolijohdeteollisuuden kysynnän ennustamismalleja olisi hyvä tutkia lisää, jotta voitaisiin varmistua siitä, että käyvätkö jotkut ennustamismallit sellaisenaan Okmeticin liiketoimintaan. Lisäksi tekoälyn hyödyntämistä kysynnän ennustamisen työkaluna voisi tutkia lisää. Myös Okmeticin tietojärjestelmien rajoitukset ennusteiden teossa ja niiden kehitystarpeet olisi oleellista selvittää.

Kandidaatintyössä esitellyt ennustamismenetelmät, erityisesti regressioanalyysi ja *MAPE*, ovat yleisiä kysynnän ennustamisessa hyödynnettäviä menetelmiä. Käytännössä ne eivät kuitenkaan toimi sellaisenaan, vaan menetelmien tukena olisi hyvä hyödyntää myös yhtä tai useampaa muuta kysynnän ennustamismenetelmää. Okmeticin tapauksessa regressioanalyysi ja *MAPE* tukisivat jo tällä hetkellä käytössä olevaa *Sales Force Composite* -menetelmää, mutta nämä työkalut voisivat olla käyttökelpoisia tukemaan myös aikasarjaan pohjautuvia menetelmiä jossain toisessa yrityksessä.

LÄHTEET

Arnold, T. J.R., Chapman, S.N. & Clive, L.M. 2008. Introduction to Materials Management. 6. painos. Upper Saddle River, New Jersey. Pearson Education, Inc. 515 s.

Bre, F., Gimenez, J., Fachinotti, V. 2017. Prediction of wind pressure coefficients on building surfaces using Artificial Neural Networks. *Energy and Buildings*. Vol. 158.

Buffa, E.S. & Sarin, R.K. 1987. Modern Production/Operations Management. 8. Painos. John Wiley & Sons, Inc. 834 s.

Carbonneau, R., Lafraamboise, K., Vahidov, R. 2008. Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research.* Vol. 184, nro. 3, s. 1140-1154.

Carbonneau, R., Vahidov, R. & Laframboise, K. 2007. Machine Learning-Based Demand Forecasting in Supply Chains. *International Journal of Intelligent Information Technologies*. Vol. 3, nro. 4, s. 40-57.

Chase, C.W. 1997. Selecting the appropriate forecasting method. The Journal of business forecasting. Vol 16, nro 3, s. 2, 23-29.

Chien, C.-F., Chen, Y.-J., Peng, J.-T. 2010. Manufacturing intelligence for semiconductor demand forecast based on technology diffusion and product life cycle. *International journal of production economics*. Vol 128, nro. 2, 496–509.

Fitzsimmons, J.A. & Fitzsimmons, M.J. 2011. Service Management: Operations, Strategy, Information Technology. 7. Painos. New York. McGraw-Hill Companies, Inc. 605 s.

Jacobs, F.R. & Chase, R.B. 2017. Operations and Supply Chain Management: The Core. 4. Painos. New York. McGraw-Hill Education. 520 s.

Kerkkänen, A. 2010. Improving demand forecasting practices in the industrial context. Väitöskirja. Lappeenrannan teknillinen yliopisto, tuotantotalouden osasto. 71 s

Mentzer, J.T. & Moon, M.A. 2005 Sales Forecasting Management: A Demand Management Approach. 2. Painos. Thousand Oaks, California. Sage Publications, Inc. 347 s.

Moon. M. A. 2018. Demand and Supply Integration: The Key to World-Class Demand Forecasting. 2. Painos. Boston. Walter de Gruyter, Inc. 234 s.

Okmetic Oy, 2021. General Presentation February 2021.

RELEX Solutions. 2021. Demand Forecasting in Retail: The Complete Guide. [WWW-dokumentti]. [viitattu 10.4.2021]. Saatavissa: https://www.relexsolutions.com/resources/demand-forecasting/

Wang, X. & Disney, S. M. 2016. The bullwhip effect: Progress, trends and directions. *European Journal of Operational Research*. Vol. 250, nro. 3, s. 691–701.
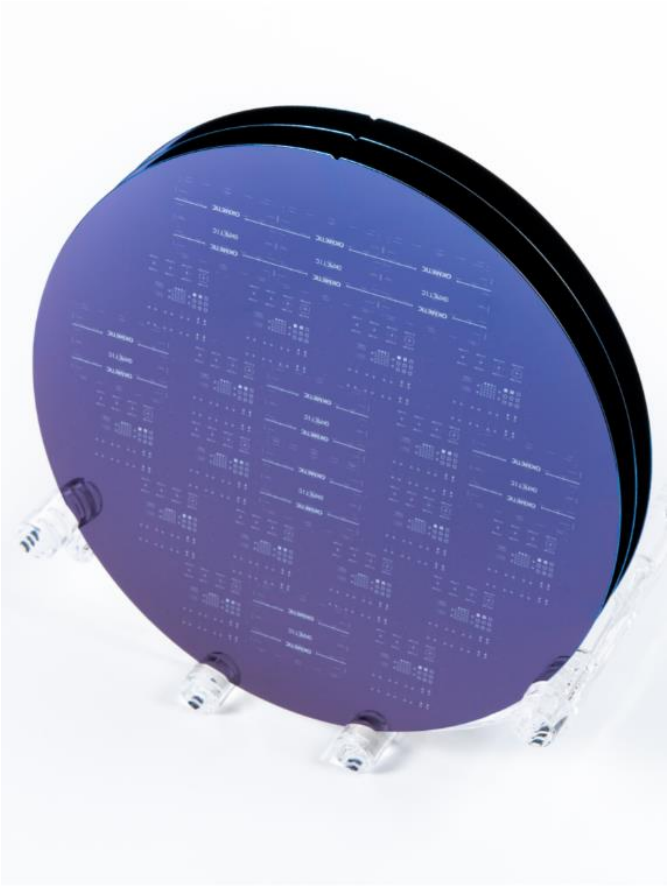
LIITE 1: OKMETIC. PIIKIEKKOJA.