

Yritystalouden ennustemallit

Business economic forecasting models

Kandidaatintyö

TIIVISTELMÄ

Tekijä: Ilmari Pekonen	
Työn nimi: Yritystalouden ennustemallit (Business economic forecasting models)	
Vuosi: 2021	Paikka: Lappeenranta
Kandidaatintyö. LUT-yliopisto, Tuotantotalous. 32 sivua, 4 kuvaa, 5 taulukkoa ja 1 liite Tarkastaja(t): Tiina Sinkkonen	
Hakusanat: Käyttöpääoma, ennustemalli, kysynnän ennustaminen, vaihtomaisuus, ostovelat, myyntisaamiset Keywords: Working capital, forecasting model, demand forecasting, inventory, accounts payable, accounts receivable	
<p>Yritysten toimintaympäristö on jatkuvassa muutoksessa ja ne tarvitsevat liiketoimintaansa liittyvien tekijöiden ennustamisesta tukea päivittäiseen päätöksentekoon ja pidemmän aikavälin suunnitteluun. Työssä selvitetään, mitä yrityksen liiketoimintaan vaikuttavia tekijöitä yritykset ennustavat, millaisia ennustemalleja kyseisten tekijöiden ennustamiseen on olemassa ja mihin ne soveltuvat parhaiten. Työ toteutetaan kirjallisuuskatsauksena perustuen liikevaihtoon, käyttöpääomaan, ennustamiseen ja ennustusmalleihin perustuvaan kirjallisuuteen, tieteellisiin artikkeleihin ja julkaisuihin.</p> <p>Yritysten on mahdollista kehittää toimintaansa entistä tehokkaammaksi, saada tilastollisesti hankittua tietoa tulevasta ja saavuttaa merkittäviä toiminnan kustannussäästöjä. Käytettävien ennustemallien tulee olla mahdollisimman yksinkertaisia, jotta yritysjohton kynnys käyttää niitä on alhainen. Yksinkertaisuus parantaa myös mallien antamien tulosten luotettavuutta ja tällaiset mallit ovat usein tarkempia kuin monimutkaiset.</p>	

SISÄLLYSLUETTELO

1	JOHDANTO.....	3
1.1	Tausta	3
1.2	Tavoite ja tutkimuskysymykset.....	3
1.3	Menetelmät, rajaus ja rakenne	4
2	YLEISTÄ ENNUSTAMISESTA.....	5
2.1	Mitä liiketoimintaansa vaikuttavia tekijöitä yritykset ennustavat.....	5
2.2	Ennustusprosessi	10
2.3	Ennustamisen hyödyt ja haasteet.....	12
3	ENNUSTEMENETELMIÄ	16
3.1	Ennustemenetelmien eroja	16
3.2	Liikevaihdon ennustaminen	16
3.3	Varaston ennustaminen	21
3.4	Ostovelkojen ja myyntisaamisten ennustaminen	23
4	JOHTOPÄÄTÖKSET JA YHTEENVETO.....	25
	LÄHTEET	28
	LIITTEET	

1 JOHDANTO

1.1 Tausta

Yritykset toimivat ympäristössä, johon vaikuttaa jatkuva muutos ja epävarmuus tulevasta. Jotta yritykset voivat tehdä päätöksiä liiketoiminnan tueksi, niiden pitää pystyä ennustamaan, miten liiketoimintaan vaikuttavat tekijät muuttuvat tulevaisuudessa (Hanke & Wichern, 2014, s. 2). Käsitys ennustamisesta on muuttunut 2000-luvun alkupuolella, kun ennustaminen on siirtynyt systemaattisempaan suuntaan ja teknologian kehittyminen on mahdollistanut paremmin prosessoidun datan käyttämisen ennusteiden pohjana (Chaman 2003, s. 3–4).

Moni saattaa ajatella, että kun menestyneen suuryrityksen liiketoiminta kuihtuu, se johtuu siitä, että yritys ei ole pystynyt reagoimaan liikeympäristön muutoksiin. Malmelin (2021, s. 17) mukaan ongelmana on kuitenkin se, että vaikka yritysjohtajilla on käytössään runsaasti tietoa tulevasta ja paljon osaamista niin johto keskittyy yleensä pyörittämään liiketoimintaa samalla tavalla kuin ennenkin. Tämä tarkoittaa yleensä sitä, että keskitytään vain lähitulevaisuuden tuloksen kasvattamiseen sekä kyseisellä hetkellä oleviin ongelmiin sen enempää tulevaisuutta miettimättä.

Etenkin teollisuusyrityksissä ennusteiden tekeminen on ollut projektiluontoista ja se ei ole liittynyt tiiviisti strategiatyöhön. Yritykset luulevatkin monesti, että ne saavat kilpailuetua käyttämällä tietoa megatrendeistä ja erilaisten instituutioiden tekemistä tutkimuksista ja julkaisuista. Tosiasiassa kuitenkin tällainen julkinen tieto ei luo mitään kilpailuetua ja sen vuoksi yritysten tulisi ottaa ennustaminen yhä tiiviimmäksi osaksi yrityksen pyörittämisen tueksi. (Malmelin 2021, s. 48–49)

1.2 Tavoite ja tutkimuskysymykset

Työn tavoitteena on selvittää, miten yritykset voivat parantaa ja helpottaa liiketoimintansa ennustettavuutta sekä päätöksentekoa yritystalouden ennustemallien avulla. Työn tutkimuskysymykset ovat:

1. Mitä liiketoimintaansa vaikuttavia tekijöitä yritykset ennustavat?
2. Mitä erilaisia ennustemenetelmiä on olemassa ja mihin ne soveltuvat?

Työn tuloksena esitetään, mitä hyötyjä ja haasteita ennustamisessa on, sekä millaisia eri ennustemalleja liiketoimintaan vaikuttavien tekijöiden ennustamiseen on ja minkälaisia edellytyksiä näiden mallien hyödyntämiseen pitää olla.

1.3 Menetelmät, raja- ja rakenne

Työ toteutetaan kirjallisuuskatsauksena, jossa hyödynnetään ennustamiseen sekä ennustemenetelmiin liittyvää tieteellistä kirjallisuutta sekä artikkeleita. Etenkin ennustemenetelmiä tutkittaessa keskitytään uudempiin tieteellisiin artikkeleihin, mutta myös vanhempaa kirjallisuutta käytetään paikoin taustatukena. Tieteelliset artikkelit valittiin työhön sillä perusteella, että käytössä oleva hakusana löytyi joko artikkelin otsikosta, tiivistelmästä tai avainsanoista. Käytettyjä hakusanoja ovat **forecast* challenge***, **forecasting benefits**, **revenue forecast***, **sales forecast* model***, **inventory forecast* model***, **demand forecast***, **working capital forecasting model**, **demand forecasting models** sekä **forecasting process**. Työ on rajattu siten, että keskitytään vain yrityksen liiketoimintaan liittyviin ennustemalleihin eikä oteta huomioon kansantaloudellisia tekijöitä ennustamisessa.

Työ koostuu neljästä luvusta, joista ensimmäinen on johdanto. Toisessa luvussa käsitellään yleisesti miksi liiketoimintaan liittyviä tekijöitä, kuten myyntiä tai vaihto-omaisuuden määrää, ennustetaan. Lisäksi luvussa tarkastellaan, minkälaisia hyötyjä ja haasteita ennustaminen pitää sisällään. Kolmannessa luvussa esitellään ennustemenetelmiä, joita voidaan käyttää yritysten liiketoimintaan vaikuttavien tekijöiden ennustamiseen. Ennustemenetelmistä esitellään niiden teoriapohja, sekä se mihin kukin malli soveltuu ja mitkä ovat mallin hyödyt ja haasteet. Johtopäätöksistä lukija saa selvän kuvan siitä, mitä ennustamisella haetaan sekä siitä, miten ennustemalleja voi hyödyntää päätöksenteon tukena.

2 YLEISTÄ ENNUSTAMISESTA

2.1 Mitä liiketoimintaansa vaikuttavia tekijöitä yritykset ennustavat

Yritysten pitkän aikavälin päätökset sekä operatiiviset päätökset perustuvat jonkinlaisiin ennusteisiin tulevasta. Ennustemallien avulla yritysten on mahdollista saavuttaa tarkempia arvioita siitä, mihin suuntaan liiketoimintaan vaikuttavat tekijät, kuten liikevaihto, vaihto-omaisuus, ostovelat ja myyntisaamiset muuttuvat. Kysynnän ennustamisen liittyy jokaiseen näiden neljän erän ennustamiseen.

Ennustamisella on tärkeä rooli yritysten liiketoiminnan suunnittelussa. Ennusteiden onnistunut sisällytys osaksi suunnitteluprosessia auttaa yritysten strategian toteuttamisessa. (Toor & Dhir 2011, s. 276) Yksi esimerkki ennustamisesta operatiivisen toiminnan tukena on työvoiman sopivan määrän määrittäminen kaupan alalla. Jos kysyntä, ja sitä kautta asiakasmäärät on ennustettu onnistuneesti, voidaan työvoiman määrä optimoida sopivaksi, mutta pieleen menneen ennusteen vuoksi työvoimasta voi olla pulaa tai sen käyttö voi olla tehotonta. (Song 2015, s. 196)

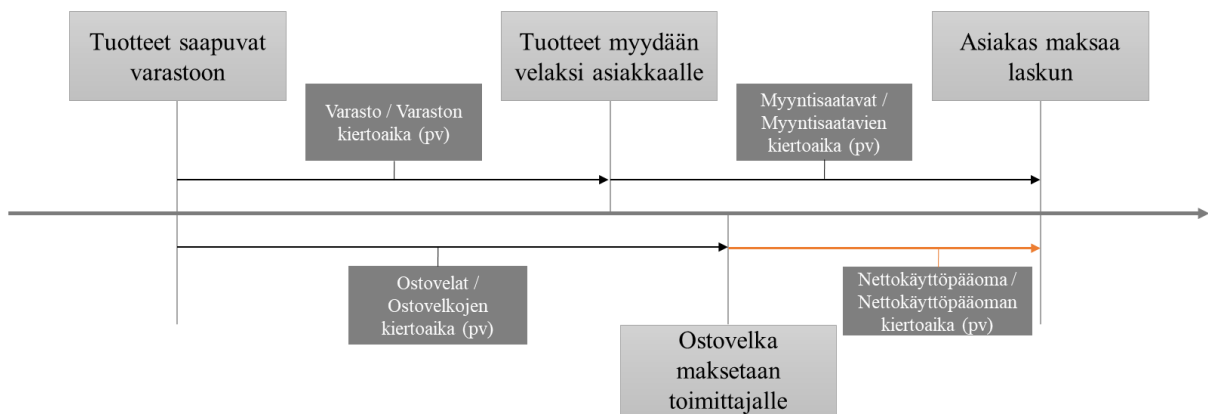
Yritystalouden ennustemalleilla tarkoitetaan malleja, joilla voidaan ennustaa liikevaihtoa, sekä käyttöpääomaan liittyviä eriä: varastoa, myyntisaamisia ja ostovelkoja kysynnän ennustamisen kautta. Tarkkojen ennusteiden avulla yritykset voivat tehdä parempia päätöksiä liiketoimintaan vaikuttavien tekijöiden osalta ja näin ollen saavuttaa kustannussäästöjä esimerkiksi käyttöpääoman määrässä. Yksi suurimmista käyttöpääoman eristä on vaihto-omaisuus ja etenkin vaihto-omaisuuden kokoa voidaan optimoida, jolloin vapautuu pääomaa yrityksen muihin tarpeisiin. (Croxtton et al. 2002, s. 51; Adepu & Erdil 2015, s. 1537) Käyttöpääomaan liittyvien erien ennustaminen on tärkeää senkin vuoksi, että se auttaa yrityksiä tekemään päätöksiä toimintansa rahoittamiseksi ja hyvällä käyttöpääoman hallinnalla yrityksen on esimerkiksi mahdollistaa saada lainaa pienemmillä kustannuksilla. Tällöin yritykset ovat lisäksi valmiita nopeisiinkin toimintaympäristön muutoksiin ja saavuttavat näin ollen kilpailuetua. (Aktas et al. 2015, s. 99; Appuhami, 2008, s. 9)

Edellä mainittujen tekijöiden ennustamiseen on kehitetty monia erilaisia malleja ja ennusteet voidaan luokitella lyhytaikaisiin ja pitkäaikaisiin ennusteisiin, makro- tai mikrotalouden ennusteisiin, tai määrällisiin ja laadullisiin ennusteisiin (Hanke & Wichern 2014, s. 2). Lisäksi

ennustemalleja tarkastellessa pitää erotella mallit kuvaileviin sekä ennustaviin. Kuvailevien mallien avulla voidaan saada ymmärrystä menneestä, mikä on tärkeää, jotta voidaan ennustaa tulevaa. Ennustavat mallit ovat taas sellaisia, joilla voidaan selkeästi ennustaa tulevia muutoksia ja sen avulla reagoida niihin. Monet ennustemallit ovatkin kuvailevia malleja, sillä ne eivät pysty ennustamaan muutosta, jos ne pohjautuvat vain menneeseen. (Strand 1999, s. 345)

Ennustemalleja on yleisesti vertailtu sen pohjalta, miten tarkkoja ennusteita ne antavat. Alstrøm ja Madsen (1994) tutkivat kuitenkin ennustemalleja tavalla, josta on enemmän hyötyä ennustemalleja miettivälle yritykselle. Ennustemalleja vertailtiin simuloimalla niitä erilaisilla kysynnöillä, minkä jälkeen ne laitettiin paremmuusjärjestykseen ennalta määritettyjen kriteerien perusteella. Ennalta määritetyt kriteerit olivat tuotteiden varastointikustannukset, tilauskustannukset sekä varaston tyhjenemiskustannukset ja mitä pienemmiksi nämä kustannukset muodostuivat, sitä paremmin malli suoriutui (Alstrøm & Madsen 1994, s. 191). Tutkimuksen tuloksena oli, että yksinkertaiset mallit suoriutuvat monimutkaisempia paremmin ja kysynnän tasoittamisella on todella iso rooli mallin suorituskyvyn kannalta (Alstrøm & Madsen 1994, s. 199–200).

Kuvasta 1 nähdään, miten yrityksen nettokäyttöpääoma muodostuu vaihto-omaisuuden ja myyntisaamisten summasta, josta on vähennetty yrityksen ostovelkojen määrä. Käyttöpääoman määrään voidaan vaikuttaa muuttamalla yksittäisiä käyttöpääoman komponentteja. Varaston kiertoaika kertoo, paljonko yrityksen varastoihin sitoutuu pääomaa ja kauanko yrityksen ostamat tuotteet ovat varastossa, ennen kuin ne myydään eteenpäin asiakkaille. Myyntisaatavien kiertoaika kertoo kauanko keskimäärin kestää, että myytyjen tuotteiden tuotot kertyvät yrityksen kassaan. Ostovelkojen kiertoaika kertoo, paljonko yritys on saanut maksuaikaa toimittajilta ja miten saatua maksuaikaa on mahdollisesti käytetty. Kyseisten komponenttien avulla nähdään, millainen osuus nettokäyttöpääomasta rahoitetaan omalla pääomalla ja vieraalla pitkäaikaisella pääomalla. (Niskanen & Niskanen 2016a, s. 121–130)



Kuva 1 Kassavirtojen aikajana (mukaiillen Niskanen & Niskanen 2016a, s. 129; Niskanen & Niskanen 2016b, s. 378)

Ideaalitilanteessa yritysten tulisi pyrkiä pienentämään myyntisaatavien sekä vaihto-omaisuuden määrää ja lisäämään ostovelkojen määrää. Tällöin käyttöpääomaan sitoutuu vähemmän pääomaa ja sitä tehokkaampaa sen hallinta on. Kuitenkin käyttöpääomavaltaisilla aloilla käyttöpääoman hallinta on erityisen tärkeää, vaikka sen määrää ei voisi pienentää. Käyttöpääoman määrä on todella riippuvainen liikevaihdosta ja vaihto-omaisuuden kasvu on yleensä välttämätöntä kasvavaan kysyntään vastaamiseksi. (Seppänen 2011, s. 120–128). Niskanen ja Niskanen (2016a, s. 130) kuitenkin toteavat, että vaikka nettokäyttöpääoman määrä tulisi minimoida pääoman vapauttamiseksi niin nettokäyttöpääoman sopiva määrä riippuu myös paljolti yrityksen sen hetkisistä toimintamalleista. Esimerkiksi yritykset, joiden taseessa vaihtuvien vastaavien osuus on suuri, käyttävät paljon enemmän ostovelkoja sekä myyntisaamisia toimintansa pyörittämiseen (Petersen & Rajan 1997, s. 684).

Liikevaihto

Liikevaihto muodostuu yrityksen varsinaisen toiminnan myyntituotoista, joka taas muodostuu myytävien tuotteiden määrästä sekä niiden yksikköhinnasta. (Niskanen & Niskanen 2016a, s. 29; Seppänen 2011, s. 124) Lisäksi liikevaihtoa voidaan käyttää tilinpäätöksen analyysin tukena, kun vertaillaan tuloslaskelman erien muutosta sekä yrityksen kannattavuutta laskettaessa (Niskanen & Niskanen 2016a, s. 87; Niskanen & Niskanen 2016b, s. 55). Liikevaihtoa tarkastellessa on myös tärkeää analysoida, miten myytävien hyödykkeiden hinnat ja myyntimäärät kehittyvät ja miten ne vaikuttavat liikevaihtoon. Liikevaihto kertoo

yritysjohdolle siitä, miten hyvin yrityksen liiketoiminnan strateginen toteutus on onnistunut. (Seppänen 2011, s. 120)

Vaihto-omaisuus

Yrityksen vaihto-omaisuus koostuu erilaisista varastoista, joita ovat aineet ja tarvikkeet, keskeneräiset tuotteet, valmiit tuotteet sekä muu vaihto-omaisuus. (Niskanen & Niskanen 2016a, s. 75) Varaston kokoon vaikuttavat kysyntä, toimialan toimintatavat sekä yrityksen omat toimintatavat ja menetelmät varaston koon määrittämiseksi. Tällaisia vaikuttavia asioita ovat esimerkiksi varmuusvarastojen koko sekä täydennyserien koko ja tiheys. (Seppänen 2011, s. 129) Toimintatapoja, jotka voivat vaikuttaa varastojen kokoon on esimerkiksi Six Sigma -metodologia, joka pyrkii vähentämään tehottomuutta yrityksen toiminnoissa. Kyseisen metodin avulla yrityksen on mahdollista pienentää tilausten läpimenoaikaa ja näin ollen pienentää käyttöpääomaan sitoutuneen pääoman määrää. (Filbeck & Krueger 2005, s. 11)

Vaihto-omaisuuden kokoon vaikuttava tekijä voi myös esimerkiksi olla se, että suuremmalla varastolla on helpompi saada enemmän maksuaikaa toimittajilta, sillä vaihto-omaisuutta pidetään helposti likvidoitavana eränä. (Choi & Kim 2005, s. 905) Pitää kuitenkin muistaa, että jos varastot ovat liian isot ja kysyntä heikkenee, niin yritys voi olla jopa vaarassa ajautua konkurssiin, kun varastoihin on sitoutunut paljon vaikeasti realisoitavaa pääomaa (Aktas et al. 2015, s. 99).

Varaston ennustamisella on tärkeä rooli, jotta varastoon ei sitoudu liikaa pääomaa. Varaston koko on optimitilanteessa sellainen, että varastossa olisi tarvittava määrä tuotteita kysyntään vastaamiseksi, mutta kuitenkin ei kuitenkaan yhtään liikaa, jotta varastoon sitoutuneet käyttöpääoman kustannukset eivät kasvaisi liian suuriksi. (Niskanen & Niskanen 2016b, s. 379) Varaston koon pienentämisellä on merkittäviä yhtäaikaista taloudellisia etuja kuten, kassavirran parantuminen, operatiivisten kustannusten pieneminen sekä pääoman vapautuminen käyttöpääomasta. Varastojen pienentäminen ei ole kuitenkaan yhtä yksinkertaista kuin ostovelkojen kasvattaminen tai myyntisaamisten pienentäminen, sillä se vaatii koko toimitusketjun toiminnan muuttamista. (Rafuse 1996, s. 62)

Joissakin tilanteissa suurempaa varastoa voidaan perustella myynnin edistämällä, kun esimerkiksi myydään tuotteita, joissa kuluttajien preferenssit vaikuttavat ostopäätökseen

vahvasti. Boada-Collado ja Martínez-de-Albéniz (2020) muotituotteisiin liittyvän tutkimuksen mukaan suurempi varasto ja sitä kautta tuotteiden parempi esillepano voi lisätä myyntiä. Tutkimuksessa mainittiin kuitenkin myös, että isompi varasto ei yksistään kasvata myyntiä vaan siihen vaikuttavia tekijöitä pitää tutkia lisää. Cachon et al. (2019) Yhdysvalloissa tehdyn autokauppaan liittyvän tutkimuksen mukaan varaston kasvattamisella on positiivinen vaikutus myyntiin. Tutkimusta tehdessä kuitenkin huomattiin, että yksistään varaston kasvattaminen, ilman, että tarjotaan asiakkaille enemmän tuotevariaatioita, pienentää myyntiä. Tämä johtuu siitä, että suurella varastolla, joka koostuu samanlaisista tuotteista ja on asiakkaan nähtävillä, on psykologisia vaikutuksia asiakkaaseen ja asiakkaat saattavat pantata ostopäätöstä tai miettiä, onko tuotteessa jotakin vikaa, kun sitä on niin paljon varastossa (Cachon et al. 2019, s. 1476–1478). Kun varastoa kasvatetaan niin, että asiakkaille tarjotaan enemmän mallivaihtoehtoja, eikä lisätä jo varastossa olevien tuotteiden määrää, myyntiä on mahdollista kasvattaa. Tämä johtuu siitä, että asiakkaiden on helpompi valita mieluisin tuote laajemmasta valikoimasta. Lisäksi huomattiin, että varastoa kierrättämällä liikkeiden välillä saatiin myyntiä kasvatettua vielä maltillisesti. (Cachon et al. 2019, s. 1484)

Varaston tyhjenemisellä voi olla vakavat seuraukset yrityksen toiminnalle. Jälleenmyyjän tai tukkukauppiaan tapauksessa yksi puuttuva tuote ei aiheuta välttämättä suuria tappioita, sillä tyypillisesti tällaisten liikkeiden asiakaskunta on laaja ja myös korvaavia tuotteita on yleensä saatavilla. Valmistajan tapauksessa puuttuva tuote voi kuitenkin tarkoittaa merkittäviä tappioita yritykselle, etenkin jos kyseistä tuotteesta ei ole tarjota mitään vastaavaa. Monet valmistajat ovatkin varautuneet tällaisiin tapauksiin ja esimerkiksi margariinivalmistajat tarjoavat tuotteita monessa eri pakkauskoossa. Usein eri tuotteet ovat myös hyvin samankaltaisia toistensa kanssa, joten kyseisellä hetkellä puuttuva tuote on helppo korvata lähes vastaavalla. (Campo et al. 2003, s. 283–284)

Ostovelat

Lähes kaikki hankinnat, mitä yritykset tekevät hankitaan velaksi. Ostovelkoja muodostuu, kun yritykset hankkivat hyödykkeitä, kuten raaka-aineita tai edelleen myytäviä tuotteita muilta yrityksiltä (Niskanen & Niskanen 2016a, s. 82). Ostovelat ovat etenkin pienten ja keskisuurten yritysten yksi tärkeimmistä rahoituksen lähteistä, sillä etenkin tällaisten yritysten voi olla vaikeaa saada rahoitusta rahoituslaitoksilta (Psillaki & Eleftheriou 2015, s. 1219; Fabbri &

Klapper 2016, s. 80). Ostovelkojen määrä taseessa vaihtelee toimialoittain. Ne voivat olla tärkein yrityksen lyhytaikaisen ulkoisen rahoituksen lähde (Niskanen & Niskanen 2016b, s. 394; Petersen & Rajan 1997, s. 661)

Ostovelkojen määrää ennustetaan sen vuoksi, että oikein käytettynä ne ovat yritykselle maksuton rahoitusmuoto toiminnan pyörittämiseksi. Ennustamalla ostovelkoja yrityksen on mahdollista selvittää ja suunnitella, tarvitseeko yritys käyttöpääoman rahoitukselle joitakin muita lyhytaikaisia rahoituslähteitä kuin ostovelkoja. (Niskanen & Niskanen 2016b, s. 399; Seppänen 2011, s. 98) Jos yritys pystyy kasvattamaan ostovelkojen määrää tai ostovelkojen kiertoaikaa, käyttöpääomaan sitoutuneen pääoman määrä pienenee ja varoja vapautuu yrityksen muihin toimintoihin (Seppänen 2011, s. 82).

Myyntisaamiset

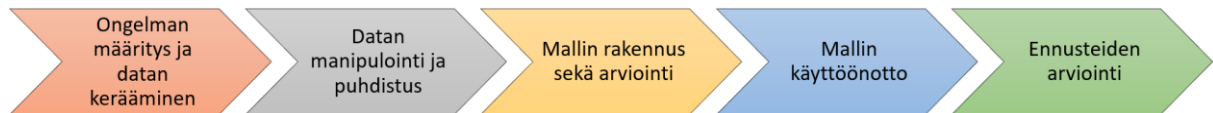
Myyntisaamiset syntyvät, kun yritykset antavat maksuaikaa myymilleen tuotteille. Maksuaikaa myönnetään yleisesti yritysten välisessä kaupassa, mutta nykyään maksuajan myöntäminen myös kuluttajille on yleistynyt. Myyntisaamisten myöntämiselle on monia eri syitä, jotka riippuvat niin antavasta kuin vastaanottavasta yrityksestä. Myyntisaamisten avulla voidaan rahoittaa asiakkaiden liiketoimintaa, jos niiden ei ole mahdollista saada rahoitusta tai hinnoittelun välineenä. Lisäksi maksuajan myöntämistä voidaan käyttää myyntityöntekijöiden tilanteissa, jossa varastot kasvavat ja myynti sakkaa ja näin ollen tarjoamalla parempia maksuehtoja asiakkaille myynti saadaan taas kasvamaan. (Niskanen & Niskanen 2016b, s. 387–389, Seppänen 2011, s. 128)

Lähtökohtaisesti myyntisaamisten määrää kannattaisi pienentää käyttöpääomaan sitoutuneiden pääomien vapauttamiseksi. Tulisi kuitenkin myös ottaa huomioon se, että maksuajan vähentäminen saattaa pienentää myyntiä, kun asiakkaat eivät esimerkiksi saa pyytämäänsä maksuaikaa. Myyntisaamisten kiertoaikaa pienentämällä yrityksen varoja vapautuu asiakkaiden toiminnan rahoittamisesta sekä käyttöpääomasta ja pääomaa on mahdollista vapauttaa yrityksen muihin toimintoihin. (Seppänen 2011, s. 81)

2.2 Ennustusprosessi

Ennustusprosessi käsittää monta eri vaihetta, joista jokainen on tärkeä ennustuksen mahdollisimman hyvän paikkansapitävyyden varmistamiseksi. Ennustusprosessin sisältö on

pysynyt samankaltaisena vuosien ajan ja ainoastaan se, missä kohtaa prosessia jokin toiminto suoritetaan, voi vaihdella. Makridakis et al. (1997, s. 13–16) ovat määritelleet ennustusprosessin 5-vaiheiseksi: 1) *Ongelman määrittely*, 2) *Datan kerääminen*, 3) *Tutkiva data-analyysi*, 4) *Mallin valinta ja sovitus* ja 5) *Ennustemallin käyttö sekä arviointi*. Hanke ja Wichern (2014, s. 5–6) kuvailevat prosessia hyvin samankaltaisesti kuin edellä, myös he ovat jakaneet ennustusprosessin viiteen eri vaiheeseen, jotka poikkeavat hieman vanhemmasta määrittelystä: 1) *Ongelman määrittely sekä datan kerääminen*, 2) *Datan manipulointi ja puhdistus*, 3) *Mallin rakennus sekä arviointi*, 4) *Mallin käyttöönotto* ja 5) *Ennusteiden arviointi* (Kuva 2).



Kuva 2 Ennustusprosessi (Hanke & Wichern 2014)

Ongelman määrittely ja datan keräys liittyvät vahvasti yhteen, sillä jo suunnitteluvaiheessa pitää varmistua siitä, että jos käytetään kvantitatiivista ennustetapaa, niin tarvittava data on olemassa ja sen pitää olla validoitua. Tarvittavan datan hankkiminen ja koonti on yleensä haastava ja aikaa vievä osa ennusteprosessia. Ongelmaa määriteltäessä on myös tärkeää miettiä sitä, kuka ennusteita tulee käyttämään, mihin tarkoitukseen ennusteita käytetään, sekä myös sitä, miten ennusteet toimivat liiketoiminnan tukena. Suunnittelua helpottaa myös se, mitä enemmän taustatietoa ratkaistavasta ongelmasta on olemassa. (Makridakis et al. 1997, s. 13–14; Hanke & Wichern 2014, s. 5)

Prosessin toinen vaihe on yksi kriittisimmistä ennustemallin mahdollisimman totuudenmukaisten sekä tarkkoja ennusteiden antamisen vuoksi. Yleisimpiä ongelmia datan kanssa ovat liian suuri tai pieni määrä dataa sekä se, että käytössä oleva data sisältää puuttuvia arvoja, jotka pitää itse arvioida ja se vaikuttaa suoraan mallin suorituskykyyn. Tässä vaiheessa dataa silmäilläään yhtenä isona kokonaisuutena esimerkiksi visualisoimalla kysyntää ja tunnistamalla datasta trendejä. (Ord & Fildes 2013, s. 15–16) Dataa voi joutua muokkaamaan tekemällä yksikkömuunnoksia ja monesta eri paikasta kerätystä datasta voidaan joutua yhdistelemään yhdeksi kokonaisuudeksi. Lisäksi on hyvä ottaa huomioon, että käytetään vain sellaista dataa, joka on relevanttia. Esimerkiksi ennustettaessa polttoainetaloudellisten autojen myyntiä polttoaineen hinnan ollessa korkealla, historiallista dataa ei kannata käyttää ajalta,

jolloin polttoaine on ollut merkittävästi halvempaa. (Makridakis et al. 1997, s. 14; Hanke & Wichern 2014, s. 5)

Kolmannessa vaiheessa käytössä oleva data sovitetaan muutamaan eri käyttöön sopivaan ennustemalliin ja pyritään minimoimaan olemassa olevalla datalla saatu ennustevirhe kokeilemalla eri mallien toimintaa. Yleensä mallia rakennettaessa pitää valita sellainen malli, joka on kehittyneempi ja tarjoaa yleensä hieman paremman ennustetarkkuuden, mutta kuitenkin sellainen, joka on tarpeeksi yksinkertainen, jotta henkilöt päätöksenteon takana ymmärtävät miten malli tuottaa ennusteet. Jos päätöksenteon takana olevat henkilöt eivät ymmärrä mallin toimintaa, niin mallin antamiin ennusteisiin on vaikea luottaa. (Makridakis et al. 1997, s. 14–15; Hanke & Wichern 2014, s. 5)

Neljännessä vaiheessa malli otetaan käyttöön ja sen avulla tehdään ennusteita. Tämän jälkeen viimeisessä vaiheessa tarkastellaan mallin antamien ennusteiden tarkkuutta ja oikeudellisuutta tekemällä ennusteita historiallisella datalla ja vertaamalla sitä tunnettuihin kysynnän arvoihin. Kun mallia on käytetty tulevaisuuden arvojen ennustamiseen ja oikeasta datasta ja mallin antamasta arvoista on tarpeeksi aineistoa niin mallia voidaan parannella ennusteiden käyttäjien ja mallin tekijöiden arvioiden pohjalta. Ennusteilla on myös yleensä sellainen vaikutus, että jos ennusteet näyttävät yrityksen toiminnan kannalta pahoilta, niin yrityksen johto pyrkii tekemään kaikkensa, jotta uhkakuvat eivät kävisi toteen. Sama pätee myös siihen, että jos ennusteet näyttävät yrityksen toiminnan kannalta hyviltä niin johto pyrkii myös silloin tekemään päätöksiä, jotka tukevat ennustettujen skenaarioiden toteutumista. (Makridakis et al. 1997, s. 15–16; Hanke & Wichern 2014, s. 5–6)

2.3 Ennustamisen hyödyt ja haasteet

Yritysten on hyvien ennusteiden avulla mahdollista saavuttaa merkittäviä liiketoiminnan kustannussäästöjä sekä saada tärkeää ja välttämätöntä tietoa tulevasta. Näitä tietoja voidaan käyttää liiketoiminnan suunnittelun tukena. Kuitenkin, jotta ennustamisesta saataisiin hyötyjä, niin pitää tarkastella minkälaisia haasteita ennusteiden tekeminen ja hyödyntäminen sisältää.

Etenkin varaston kokoa suunniteltaessa on tärkeää ottaa huomioon myös kysynnän epävarmuus. Hyvät ennustemallit linkittyvät tosiasialliseen kysyntään, mutta kuitenkin poikkeuksellisen korkean kysynnän aikana varastot saattavat loppua kesken tai

poikkeuksellisen matalan kysynnän aikana liian suuresta varastosta voi tulla turhia varastointikustannuksia. Epätarkat ennusteet maksavatkin yritykselle rahaa menetettyjen myyntien tai esimerkiksi liian suurten varastojen vuoksi. (Kourentzes et al. 2020, s. 1)

Ennustamisessa käytettävä data sisältää lähes aina jonkinlaisia virheitä. Virheet voivat johtua satunnaisuudesta tai sitten systemaattisesta virheestä, joka on voinut tapahtua datan keräämisen tai syöttämisen aikana. Datan satunnaisvaihtelu voidaan ottaa huomioon ennusteiden epävarmuustekijöissä, mutta systemaattista virhettä ei ole välttämättä helppoa ottaa huomioon. Virheet vaikuttavat sitä enemmän, mitä monimutkaisempia malleja käytetään. Mitä huonompaa dataa yrityksillä on käytössä, sitä yksinkertaisempia malleja tulisi käyttää. Jos voidaan varmistua siitä, että käytettävä data on hyvän laatuista, niin silloin on mahdollista käyttää monimutkaisempia malleja, joiden toiminta ja tarkkuus riippuu paljolti datan laadusta. (Strand 1999, s. 341–343)

Ennustamisen yhtenä ongelmana on myös se, miten määritellä, kuinka hyvä jokin malli on. Perinteisesti kysynnän ennusteiden tarkkuutta on mitattu keskipoikkeaman (Mean Absolute Error, MAE) tai keskineliövirheen (Mean Squared Error, MSE) avulla, joita on helppo ja yksinkertaista käyttää, mutta sen lisäksi on olemassa kolme muuta yleisesti käytössä olevaa tarkkuuden arviointi tapaa: prosentuaalinen keskipoikkeama (Mean Absolute Percentage Error, MAPE), suhteellinen poikkeama (Relative Absolute Error, RAE), sekä Hyndman ja Koehler (2006b) vuonna 2006 esittelemä menetelmä: skaalattu keskipoikkeama (Mean absolute scaled error, MASE) (Taulukko 1). (Axsäter 2015, s. 25–26, Hyndman & Koehler 2006b, s. 682)

Taulukko 1 Ennustevirheen mittausmenetelmiä (Hyndman 2006a)

Menetelmä	Käyttökohde	Hyödyt	Haasteet
Keskipoikkeama / MAE – Mean Absolute Error	Ennustemallin arviointi yhden datasetin kohdalla	Yksinkertainen käyttää ja tulkita	Ei skaalautu koon mukaan, joten ei voida käyttää eri menetelmien vertailuun
Keskineliövirhe / MSE – Mean Square Error	Ennustemallin arviointi yhden datasetin kohdalla	Yksinkertainen käyttää ja tulkita	Ei skaalautu koon mukaan, joten ei voida käyttää eri menetelmien vertailuun
Prosentuaalinen keskipoikkeama / MAPE – Mean Absolute Percentage Error	Ennustemallin vertailu monen datasetin välillä	Skaalautuva, joten voidaan vertailla mallin toimivuutta eri dataseiteillä	Virheen arvot voivat lähestyä ääretöntä Rankaisevat positiivista virhettä enemmän kuin negatiivista Ei voida käyttää epäsäännöllisessä kysynnässä, jos kysynnän arvo on välillä 0
Suhteellinen poikkeama / RAE – Relative Absolute Error	Vaihtoehtoinen tapa prosentuaaliselle keskipoikkeamalle	Skaalautuva, joten voidaan vertailla mallin toimivuutta eri dataseiteillä	Virheen arvot voivat lähestyä ääretöntä, kun virhe-erot ovat pieniä Ei voida käyttää epäsäännöllisessä kysynnässä, jos kysynnän arvo on välillä 0
Skaalattu keskipoikkeama / MASE – Mean Absolute Scaled Error	Monen eri datasetin vertailu tai monen eri mallin vertailu yhden datasetin kohdalla	Skaalautuva ja voidaan käyttää kaikkien datasettien ja mallien vertailuun	Ei voida käyttää, kun kysyntä on täysin tasaista

MAPE-menetelmä skaalautuu kysynnän mukaan ja sitä voidaan käyttää eri tuotteiden ennusteiden vertailuun, se on myös skaalautuva, mutta se rankaisee positiivista virhettä enemmän kuin negatiivista ja sitä ei voi käyttää, jos kysyntä on välillä nolla. RAE menetelmä on myös skaalautuva, mutta tässä metodissa käytetyn mallin keskipoikkeama jaetaan vertailumallin, joka on yleensä naiivi malli, keskipoikkeamalla. Naiivin metodin antama kauden ennuste on edellisen kauden toteuma. RAE menetelmän heikkous on kuitenkin se, että sitä ei voi käyttää, jos virhe-ero on todella pieni, sillä se johtaa äärettömiin arvoihin, tai kysyntä käy välillä nollassa. MASE menetelmässä saatu virhe suhteutetaan naiivin ennustemenetelmän

MAE metodilla saatuihin edellisen kauden ennusteen virhearvoihin. Jos virheen arvoksi saadaan alle 1 niin käytetyn ennustemenetelmän ennuste on parempi kuin naiivin menetelmä ja jos arvo on yli 1 niin silloin naiivin menetelmän ennuste on parempi. (Hyndman 2006a, s. 44–45; Hyndman & Koehler 2006b, s. 686–687, Hyndman et al. 2008, s. 26) Tarkemmat kaavat edellä lueteltujen menetelmien laskentaan löytyvät liitteestä 1 (kaavat 1–6).

Tilanteissa, joissa kysyntä on epäsäännöllistä, ennusteiden tekeminen ja niiden tarkkuuden mittaaminen on hankalaa (Mathai et al. 2016, s. 214). Hyndman (2006a) tekemän tutkimuksen mukaan edellä mainituista metodeista MASE on paras mittari tarkkuuden mittaamiseen etenkin silloin kun kysyntä on epäsäännöllistä, sillä sen avulla voidaan vertailla eri ennustemalleilla tehtyjä ennusteita ja eri tuotteiden kysynnästä tehtyjä ennusteita. MASE on ainut menetelmä, jota voidaan käyttää lähes kaikissa tilanteissa.

3 ENNUSTEMENETELMIÄ

3.1 Ennustemenetelmien eroja

Yrityksen toimintaan vaikuttavien tekijöiden ennustamiseen on kehitetty monia erilaisia ennustemalleja, joista lähes kaikki pohjautuvat kysynnän ennustamiseen. Ennustemalleja löytyy niin yleisiin tilanteisiin, kuin yrityksille spesifeihin tarpeisiin tehtyjä. Lisäksi jotkin ennustemallit soveltuvat paremmin esimerkiksi epätasaisen kysynnän ennustamiseen kuin toiset ja ovat monimutkaisempia käyttää kuin toiset. Taulukkoon 2 on kerätty muutamia erilaisia ennustemalleja, joista osa käydään läpi erilaisten esimerkkien ja casejen kautta.

Taulukko 2 Ennustemenetelmiä

Menetelmä	Käyttökohde
Naiivi	Vertailukohta muille ennustemalleille
Vakiomalli	Täysin tasaisen kysynnän ennustaminen
Eksponentiaalinen tasoitus	Tasainen kysyntä, jota korjataan tasoitusvakiolla
Liukuva keskiarvo	Tasainen kysyntä, jossa muutoksia hillitään historiallisen ajanjakson keskimääräisen kysynnän avulla
Syvä neuroverkko	Epäsäännöllinen kysyntä
VAR – vektori autoregressiomalli	Satunnaisen ja kausittaisen kysynnän ennustaminen
BVAR – Bayesin vektori autoregressiomalli	Satunnaisen ja kausittaisen kysynnän ennustaminen
ARIMA	Tasaisen kysynnän ennustaminen (mahdollista myös ennustaa trendiä tai kausiluontoista kysyntää muutoksilla), mahdollista mallintaa satunnaisuuteen perustuvien aikasarjojen käyttäytymistä

3.2 Liikevaihdon ennustaminen

Yksi tärkein tekijä liikevaihdon ennustamisessa on ennusteiden tarkkuus, sillä pieleen menneillä ennustuksilla kysyntään vastaaminen voi epäonnistua tai yritys voi varautua liian suureen kysyntään, mikä luo lisää kuluja. Perinteisimmät liikevaihdon ennustusmenetelmät perustuvat aikasarja-analyysiin ja muihin yksinkertaisiin malleihin, joiden toiminta perustuu historialliseen dataan. Tällaiset menetelmät soveltuvat hyvin tilanteisiin, joissa kysyntä on tasaista tai sisältää hyvin tunnettuja kausitrendejä. (Chang et al. 2021, s. 379; Hanke & Wichern 2014, s. 119)

Tasainen kysyntä

Yksinkertaisin ennustemenetelmä on naiivi ennustemenetelmä, siinä oletetaan, että kysyntä on seuraavalla jaksolla sama kuin edellisellä jaksolla. Naiivia malleja ei yleensä käytetä ennustamiseen vaan ennusteiden arvioinnin tukena, mutta yhtä yksinkertaisimmista ennustemalleista, vakiomallia, voi pitää lähes naiivina ennustemallina. (Guerard & Thomakos 2004, s. 54)

Vakiomallia voidaan käyttää etenkin sellaisten tuotteiden myynnin ennustamiseen, jotka ovat olleet jo markkinoilla kauan, ja joiden kysyntä ei riipu ulkopuolisista tekijöistä. Esimerkki tällaisen tasaisen kysynnän omaavasta tuotteesta on esimerkiksi hammastahna tai pyykinpesuaine. Kyseisen mallin avulla kysynnän arvoksi saadaan tuotteen keskimääräinen kysyntä, johon lisätään itsenäinen satunnaismuuttuja. Jos tuotteen keksimääräistä kysyntää ei tiedetä, niin se voidaan selvittää laskemalla aiempien jaksojen keskimääräisen kysyntä kullekin jaksolle. Tilanteessa, jossa keskimääräinen kysyntä ei pysykään vakiona vaan muuttuu, pitää käyttää muita ennustemalleja. (Axsäter 2015, s. 9)

Aikasarjat ovat datasettejä, joissa jokin muuttujan arvo on sidottu aikaan. Esimerkki aikasarjasta on päivittäinen liikevaihto useana peräkkäisenä päivänä tai kuukausittainen työttömyystilanne. Peräkkäiset havainnot aikasarjoissa liittyvät tyypillisesti toisiinsa. (Hanke & Wichern 2014, s. 119, Hyndman et al. 2008, s. 3–4) Tilanteessa, jossa kysyntä ei seuraa pitkällä aikavälillä mitään trendiä, mutta saattaa kuitenkin vaihdella jaksoittain edestakaisin, voidaan käyttää eksponentiaalisen tasoituksen mallia tai liukuvan keskiarvon mallia, joka on osa ARIMA-mallia. ARIMA lyhenne tarkoittaa autoregressiivistä integroitua liukuvan keskiarvon prosessia. ARIMA mallien yleinen esitysmuoto on kaavan 11 (Liite 1) mukainen. Edellä mainitut mallit ovat suosittuja helppokäyttöisyytensä vuoksi ja ne käyttävät hyväkseen aikasarja-analyysia. (Axsäter 2015, s. 9, Schmidhuber 2015, s. 381)

Eksponentiaalinen tasoitus ottaa huomioon ennustetta tehdessään edellisen jakson toteutuneen kysynnän sekä edellisen jakson ennusteen, jota se korjaa tasoitusvakiolla ja sen avulla tuottaa ennusteen seuraavalle jaksolle. (Axsäter 2015, s. 11–12; Hyndman et al. 2008, s. 13) Mallin toimintaa on mahdollista hallita muuttamalla tasoitusvakioita. Tasoitusvakio voi saada arvot väliltä 0 ja 1, jolloin jos sen arvo on 0, niin seuraavan kauden ennusteena käytetään edellistä ennustetta ja jos sen arvo on 1 niin seuraavan kauden ennusteena käytetään edellisen kauden

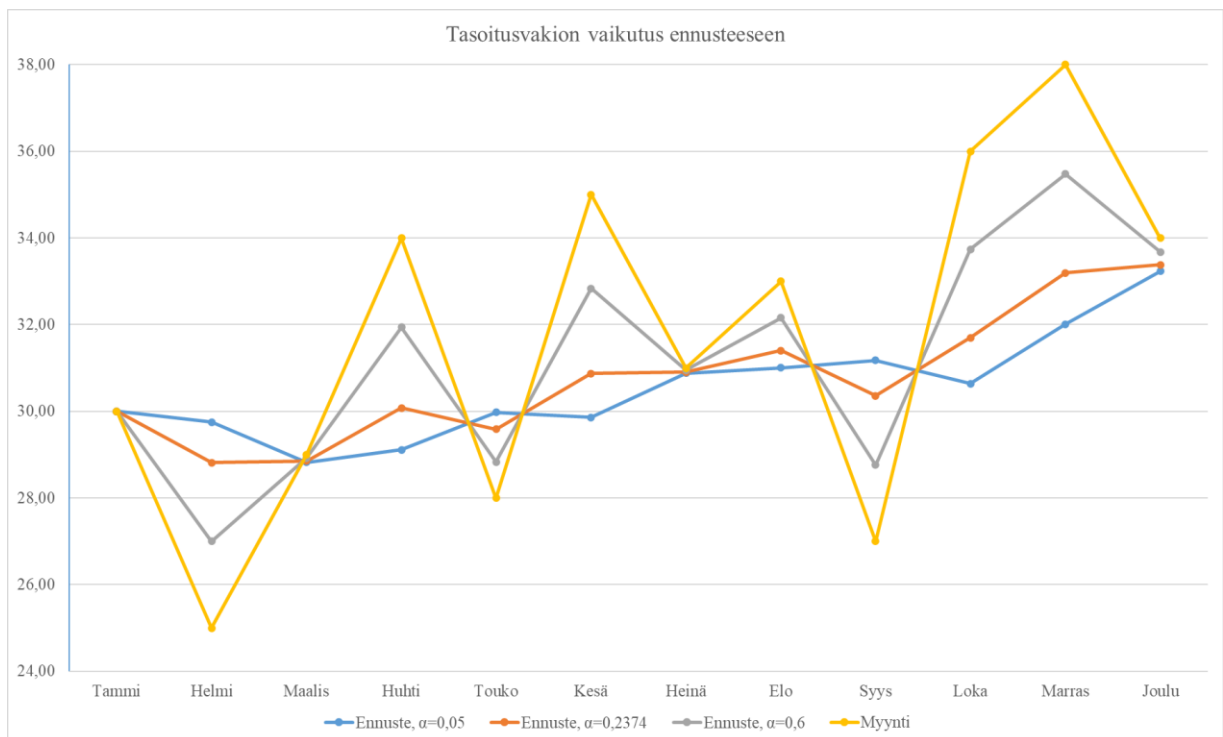
toteumaa. (Axsäter 2015, s. 12) Hyndman et al. (2008, s. 23–24) mukaan sopivien parametrien valinta muodostuu yleensä ongelmaksi malleja rakennettaessa. Sopivia parametrien arvoja voidaan lähteä hakemaan kokeilemalla monia eri arvoja, mutta järkevämpi tapa on käyttää esimerkiksi metodia, jonka avulla minimoidaan ennustevirhe. Yksi yleisimmistä tavoista on minimoida MSE arvo historiallisesta kysynnän arvosta valitsemalla se tasoitusvakion arvo, joka tuottaa pienimmän virheen. Tasoitusvakion arvoksi valitaan yleisesti jotakin 0,1 ja 0,3 väliltä ja tasoitusvakion arvo on sitä pienempi, mitä lyhyempi ennustejakso on kyseessä (Axsäter 2015, s. 13). Yksi tyypillinen eksponentiaaliseen tasoitukseen liittyvä haaste on myös se, että kun kysynnän trendi on kasvava niin kysyntäennuste antaa liian pieniä ennusteita ja kun trendi on laskeva niin ennusteet ovat liian suuria (Shoemith & Pinder 2001, s.1269).

Taulukosta 3 nähdään, miten tasoitusvakion arvo voidaan määrittellä aiempien jaksojen toteutuneiden kysyntöjen ja ennustettujen kysyntöjen avulla. Taulukossa 3 ensimmäisen kuukauden ennuste on oletettu oikeaksi ja seuraavien kuukausien ennusteet on laskettu kaavan 7 (Liite 1) mukaisesti. Tasoitusvakion optimaalinen arvo on saatu käyttäen Excelin Solver - ominaisuutta, jonka avulla minimoitiin ennusteiden antama keskineliövirhe. Tasoitusvakiota laskettaessa raja-arvona oli se, että vakion pitää sijoittua välille 0 ja 1, jolloin pienimmän virheen antama tasoitusvakion arvo on 0,2374.

Taulukko 3 Optimaalisen tasoitusvakion määrittäminen minimoimalla historiallisen kysynnän MSE (mukaillen Tarkkala 2020)

Kuukausi	Myynti	Ennuste	Ennuste virhe	MSE
Tammi	30	30		
Helmi	25	30,00	-5,00	25,00
Maalis	29	28,81	0,19	0,03
Huhti	34	28,86	5,14	26,45
Touko	28	30,08	-2,08	4,32
Kesä	35	29,58	5,42	29,32
Heinä	31	30,87	0,13	0,02
Elo	33	30,90	2,10	4,41
Syys	27	31,40	-4,40	19,35
Loka	36	30,36	5,64	31,87
Marras	38	31,70	6,30	39,75
Joulu	34	33,19	0,81	0,65
			MSE	16,47
			alfa	0,2374

Kuvassa 3 on esitetty miten eksponentiaalinen tasoitus ennustaa kysyntää eri tasoitusvakion arvoilla. Havainnollistamista varten tasoitusvakion arvoina on käytetty arvoja 0,05; 0,6 sekä optimaalista tasoitusvakion arvoa 0,2374 joka on otettu taulukon 3 esimerkistä. Kuten kuvasta 3 huomataan, mitä suurempi tasoitusvakion arvo on, sitä enemmän ennuste heittelee kysynnän mukana. Pienemmällä tasoitusvakion arvolla ennuste seuraa kysynnän muutoksia paljon maltillisemmin, ilman suuria heilahduksia.



Kuva 3 Tasoitusvakion vaikutus ennusteeseen


Epäsäännöllinen kysyntä

Kysynnän ollessa epäsäännöllistä perinteiset ennustemenetelmät eivät enää anna realistisia ennusteita. Perinteisten metodien rinnalle on viime vuosina noussut tekoälyä ja koneoppimista hyväksikäyttäviä ennustemalleja. Tällaisten uusia teknologioita käyttävien mallien avulla on mahdollista saavuttaa merkittävästi tarkempia kysynnän ennusteita. (Chang et al. 2021, s. 379–380)

Farmasia-alan tukkukaupassa myynnin ennustaminen on ollut todella vaikeaa, sillä lääkkeiden menekki ei yleisesti mukaile mitään tiettyä kaavaa ja myynti saattaa heitellä ajoittain paljon. Perinteiset ennustemenetelmät johtavat usein korkeisiin varastonpitokustannuksiin, sillä ne

mukailevat yleensä tuotteiden korkeampia kysyntöjä (Chang et al. 2021, s. 379). Chang et al. (2021) ovat kehittäneet ennustemallin lääkemyyntien ennustamiseen, mikä käyttää hyödykseen syväoppimista. Syvät neuroverkot ovat viime vuosien aikana mahdollistaneet ennustemenetelmien ja koneoppimisen kehittymisen radikaalisti. Syväoppiminen käyttää hyväkseen neuroverkkoa, joka koostuu monesta toisiinsa linkitetystä neuroneista. Jokaisessa neuronissa suoritetaan laskutoimitus siihen saapuneen tiedon avulla. Laskutoimituksen jälkeen tieto lähetetään neuronin aktivointifunktiolle ja eteenpäin seuraavalle tasolle, jos aktivointifunktion raja-arvo ylittyy, kunnes päästään verkon viimeiselle tasolle ja saadaan neuroverkon antama tulos. (Schmidhuber 2015, s. 86–87)

Chang et al. (2021) kehittämä ennustemalli sisältää yhteensä 6 tasoa, joista ensimmäinen on datan syöttö -taso, joka sisältää 19 neuronina. Seuraavat 4 tasoa ovat piilotasojia, joista jokainen sisältää 38 neuronina ja viimeisenä on tulos -taso, joka sisältää vain yhden neuronin (Kuva 4). Yhteensä neuroverkko koostuu 143 neuronista, jotka käyttävät ReLu -aktivointifunktiota hyväkseen.



Kuva 4 Changin käyttämä neuroverkko myynnin ennustamisessa (mukaillen Chang et al. 2021, s. 382)

Mallia rakennettaessa sitä koulutettiin käyttämällä viikoittaista myyntidataa viimeiseltä kolmelta vuodelta. Jokaiseen neuronin syötettiin viikoittainen myynnin arvo ennustehetkestä edellisen 16 viikon ajalta ja lisäksi kolmeen muuhun neuronin syötettiin tieto siitä, mikä päivä, kuukausi ja vuosi on menossa. Syötetty tieto normalisointiin siten, että jokaiseen neuronin syötetty arvo oli jotakin väliltä 0 ja 1. Ensimmäiset kolme tasoa ovat osa autoenkooderia.

Autoenkooderi on itsevalvova koneoppimismalli, jonka tarkoituksena on replikoida siihen syötettyä dataa poistamalla syöttödatan kohinaa (Yan 2021, s. 65–68). Autoenkooderi koulutettiin 1000 syklin vastavirta-algoritmin avulla, jolloin saatiin minimoitua mallin antama virhe. Autoenkooderi lähettää datan aktivointifunktion kautta eteenpäin seuraavalla kahdelle tasolle, jotka hoitavat itse myynnin ennustamisen. Myös nämä kaksi tasoa neuroverkosta koulutettiin samalla tavalla kuin autoenkooderi. Lopulta viimeisessä tasossa saadaan itse myyntiennuste. (Chang et al. 2021, s. 382–386)

Mallin toimintaa arvioitiin siten, että mallin antama ennuste oli onnistunut, jos virhe oli maksimissaan 20 % oikeasta arvosta. Luotu malli onnistui ennustamaan todella hyvin 1000 eri tuotteen myynnit noin 73,3 % prosentin tarkkuudella, joka on paljon parempi kuin 50 % odotusarvo. Eksponentiaalisen tasoituksen malliin verrattuna, mallin avulla pystytiin saavuttamaan tarkempia myynnin ennusteita ja sen avulla pienentämään varastointikustannuksia. (Chang et al. 2021, s. 387–388)

3.3 Varaston ennustaminen

Kysyntäennusteiden tarkkuus on ratkaisevassa asemassa etenkin tuotannossa, jossa tuotteita tuotetaan varastoon. Suurin osa vähittäiskaupan tuotteista kuuluu tähän kategoriaan. Raaka-ainetilaukset sekä tuotanto kytkeytyvätkin tämän vuoksi vahvasti kysynnän ennustamiseen. (Kück & Freitag 2021, s. 1) Hyvillä kysyntäennusteilla yritysten on mahdollista saada kustannussäästöjä varaston osalta. Shoesmith ja Pinder (2001) esittävät kysynnän ennustamiseksi vektori autoregressiomallia (VAR) sekä Bayesin vektori autoregressiomallia (BVAR), jotka ovat molemmat kehittyneitä aikasarja-analyysiin perustuvia ennustemenetelmiä ja tarkemmat kaavat löytyvät liitteestä 1 (kaavat 8–9). Kyseisiä malleja käytettiin tutkimuksessa kolmen erilaisen kysynnän ennustamiseen ja tutkimuksen tuloksena oli, että kyseisten mallien avulla on mahdollista pienentää varastoon sitoutuneita kustannuksia merkittävästi.

VAR sekä BVAR on esitelty jo vuonna 1979, mutta ovat edelleen käytössä, sillä ne ovat osoittaneet tarkkuutensa monissa eri ennustustilanteissa. VAR-mallin vahvuutena on myös, että se mahdollistaa muuttujien välisten pitkäaikaisten suhteiden tutkimisen yhdessä lyhytaikaisten dynaamisten muutosten kanssa (Hacker & Hatemi-J 2008, s. 602). Kyseisiä malleja on yleensä käytetty tilanteissa, joissa löytyy paljon historiallista dataa. BVAR-malli on kuitenkin myös toimiva tilanteissa, joissa dataa historiallisen datan määrä on pieni. VAR malli esiteltiin

vaihtoehdoksi suurille kompleksisille ennustemalleille, joiden ennustetarkkuus ei ole ollut hyvä siitäkään huolimatta, että ne ottivat huomioon paljon asioita. Yksinkertaisen VAR mallin toiminta perustuu historiallisten talouden lukujen toteutumien toistuvien kuvioiden käyttöön ennustetta tehdessä. BVAR mallissa sovelletaan Bayesin teoriaa VAR malliin, jonka avulla pystytään vaikuttamaan VAR mallissa piilevään yliparametrisoinnin ongelmaan.

Esitelläkseen mallien toimintaa eri tilanteissa, Shoemith ja Pinder (2001) käyttivät esimerkkinä kolmea erilaista kysyntää: 1) *Traktorin lisälaitteen kysyntä*, 2) *Traktorin öljynsuodattimen kysyntä* ja 3) *Lentokoneen penkin osan kysyntä*. Eri aikasarjat eroavat hieman toisistaan: ensimmäisestä löytyy kausiluontoisuutta, toisesta löytyy myös hieman kausiluontoisuutta, mutta myös satunnaisuutta ja kolmannessa kysyntä on aluksi suurta, mutta pienenee nopeasti ja jää vakaaksi. Kyseiset tuotteet valittiin tutkimukseen sen vuoksi, että ne kuvastavat useasti kohdattuja varastonhallinnan haasteita, kuten kausiluontoisuutta, hyvin. Kyseiset aikasarjat ovat tarpeeksi suuria kausiluontoisuuden näyttämiseen ja yhden testikauden käyttämiseen, sarjat ovat kuitenkin tarpeeksi lyhyitä, että niiden avulla voidaan osoittaa mallien toimivuus operatiivisen toiminnan tukena ja verrattain pienilläkin otoksilla.

Mallien tuloksia vertailtiin MAPE menetelmän avulla ja mallien antamia optimaalisia varaston kokoja vertailtiin Wagner-Whiten algoritmin sekä kahden muun menetelmän antamiin optimaalisiin varaston kokoihin. Wagner-Whiten (WW) menetelmä antoi pienimmän optimaalisen varaston koon, koska se pystyy sopeutumaan kysynnän vaihteluihin parhaiten, joten käytämme vertailuun vain sitä. Jotta mallien tuloksia voitiin mitata, jokaisen kysynnän optimaalinen palveluaste määriteltiin käyttäen apuna kaavaa 10 (Liite 1). Kaavaa hyväksikäyttäen optimaalisen palveluaste saadaan vähentämällä liian suuren täyttöasteen todennäköisyys luvusta 1. Jokaisen tuotteen palveluasteeksi saatiin yli 90 % suurten puutekustannusten vuoksi (Shoemith & Pinder 2001, s. 1272).

Tutkimuksen tuloksena oli, että käyttämällä VAR ja BVAR malleja, MAPE oli näillä malleilla pienin sekä optimaaliset varaston koot olivat vain noin 30–55 % prosenttia suurempia kuin WW menetelmällä laskettu optimaalisen varaston koko. Eksponentiaalisen tasoituksen avulla varastoon koot olivat noin 40–170 % prosenttia suurempia. (Shoemith & Pinder 2021, s. 1273) Voikin todeta, että kun malleja käytetään yhdessä WW menetelmän avulla, niin yritysten on

mahdollista pienentää varastoon sitoutuneita kustannuksia merkittävästi etenkin siirtyessään pois eksponentiaalisen tasoituksen käyttämisestä, mikä on verrattain yleinen ennustustapa.

3.4 Ostovelkojen ja myyntisaamisten ennustaminen

Yleinen ja helppokäyttöinen ostovelkojen ja myyntisaamisten ennustusmenetelmä on suhteuttaa ostovelkojen ja myyntisaamisten määrä liikevaihtoon ja käyttää kyseistä suhdetta ennustettaessa kyseisten erien määrää tuleville vuosille. Kyseinen ennustemenetelmä on perusteltu sen vuoksi, että kyseisille erille on ominaista muuttua liikevaihdon mukana. Yrityksen liikevaihdon kasvu tarkoittaa yleensä myös myynnin kasvamista ja siten myös yleensä myyntisaamisten kasvamista. Liikevaihdon kasvaessa myös ostoille käy yleensä samalla tavalla ja se kasvattaa ostovelkojen määrää. Jotta kyseistä ennustusmenetelmää voi käyttää, niin tulevan tai tulevien vuosien liikevaihdon tulisi olla ennustettuna. (Niskanen & Niskanen 2016a, s. 243–245)

Taulukosta 4 nähdään, että jos vuonna t yrityksen liikevaihto on 2 500 000 € ja myyntisaamisten ja ostovelkojen määrä on 160 000 € niin silloin kyseisten erien osuus liikevaihdosta on 6,4 %. Tämän suhdeluvun avulla voidaan ennustaa myyntisaamisten ja ostovelkojen määrä vuosille $t + 1$ ja $t + 2$ käyttämällä hyväksi kyseisille vuosille tehtyjä liikevaihdon ennusteita sekä aikaisempina vuonna laskettua suhdelukua.

Taulukko 4 Myyntisaamisten ja ostovelkojen määrän ennustaminen suhdeluvun avulla

Aika	t	$t + 1$	$t + 2$
Liikevaihto, €	2 500 000	2 750 000	2 900 000
Myyntisaamiset / Ostovelat, €	160 000	176 000	185 600
Osuus liikevaihdosta, %	6,4	6,4	6,4

Ostovelkoja voidaan ennustaa myös edistyneemmällä tavalla kuin suhteuttamalla niitä liikevaihtoon. Kadochnikova et al. (2019) tutkivat ARIMA-mallien hyödyntämistä ostovelkojen ennustamisessa suuressa teleliikennealan yrityksessä. Malleja alettiin käyttää enemmän ja ne nousivat suosituimmaksi vuonna 1970 George Boxin ja Gwilym Jenkinsin toimesta. Mallien avulla on mahdollista mallintaa satunnaisuuteen perustuvien aikasarjojen käyttäytymistä (Box et al. 2016, s. 2). Kyseiset mallit yhdistävät autoregressiiviset, liukuvan keskiarvon sekä yhdistetyt autoregressiiviset liukuvan keskiarvon mallit (Shumway & Stoffer 2006, s. 84). Yleisesti mallia käytetään sellaisen kysynnän ennustamiseen, joka on satunnaista

ja stationaarista. Stationaarisuus tarkoittaa sitä, että aikasarjan tilastolliset ominaisuudet pysyvät muuttumattomina. Kysyntä voi muuttua, mutta tapa, jolla kysyntä muuttuu, pysyy samana. (Axsäter 2015, s. 24–25; Palachy 2019)

Ostovelkojen ollessa yksiulotteinen ja stationaarinen aikasarja, ARIMA-mallin käyttö on mahdollista, koska se antaa yleensä hyviä tuloksia lyhyen aikavälin ennustamiseen. Kadochnikova et al. (2019) tutkimuksessa tutkittiin viiden erilaisen ARIMA-mallin käyttäytymistä ja tuloksena oli, että yksi yksinkertaisimmista luoduista malleista, ARIMA(0,1,1), suoriutui parhaiten ostovelkojen ennustamisessa. Arviointikriteerinä käytettiin ennusteen ja oikean kysynnän välistä virhearvoa.

ARIMA-mallien käyttöä puoltaa se, että mallit pyritään luomaan mahdollisimman yksinkertaisiksi ja se, että ne perustuvat selkeästi matemaattisiin ja tilastollisiin menetelmiin, mikä tekee malleista eniten tieteellisesti perusteltuja verrattuna muihin aikasarjojen ennustamiseen luotuihin malleihin. Hyvän tieteellisen pohjan lisäksi ARIMA-mallien käyttöä puoltaa myös se, että mallien teko ja oikean mallin valinta on tehty todella yksinkertaiseksi ja jopa automatisoiduksi. ARIMA-mallien käyttöön liittyy kuitenkin myös haasteita. Mallia rakennettaessa tarvitaan paljon dataa, ainakin 40 edelliseltä jaksolta, mikä ei ole aina mahdollista etenkin uudempien yritysten tai uusien tuotteiden tai palveluiden kohdalla. Lisäksi 1990-luvun lopussa ennustajat ovat tehneet huomion, että ARIMA-mallit eivät yleisesti ottaen ole parempia kuin eksponentiaalisen tasoituksen mallit, yksinkertaiset autoregressiiviset mallit tai yksinkertaiset yhdistetyt autoregressiiviset liukuvan keskiarvon mallit. (Kadochnikova et al 2019, s. 72–74)

4 JOHTOPÄÄTÖKSET JA YHTEENVETO

Työn tavoitteena oli selvittää miksi yritykset ennustavat liiketoimintaansa vaikuttavia tekijöitä, mitä tekijöitä ne ennustavat sekä ennustemallien tuomia hyötyjä ja haasteita. Lisäksi työssä selvitettiin, mitä erilaisia ennustemalleja on olemassa sekä mihin käyttötarkoituksiin ne sopivat. Ensimmäinen tutkimuskysymys oli:

1. Mitä liiketoimintaansa vaikuttavia tekijöitä yritykset ennustavat?

Yritykset joutuvat päivittäin tekemään päätöksiä operatiivisen toimintansa pyörittämiseksi. Alati muuttuva toimintaympäristö kuitenkin vaikeuttaa päätösten tekemistä. Päätösten tukena yritykset käyttävät erilaisia ennustemenetelmiä, ennusteiden tekeminen ei kuitenkaan ole välttämättä osana yritysten päivittäisessä toiminnassa tai strategiaprosessissa. Työssä selvisi, että yrityksiä kiinnostaa, miten liikevaihto, vaihto-omaisuuden määrä, ostovelat ja myyntisaamiset muuttuvat, sillä näiden tietojen avulla yritys saa paljon tietoa esimerkiksi siitä, miten sen kassavirrat liikkuvat ja paljonko käyttöpääoma sitoo yrityksen varoja. Mitä enemmän pääomaa sitoutuu käyttöpääomaan, sitä enemmän yrityksen pitää käyttää lyhytaikaisia rahoituksen lähteitä sen rahoittamiseksi.

Työssä havaittiin, että ennustamisen avulla yritysten on mahdollista saada merkittäviä kustannussäästöjä, kilpailuetua muihin yrityksiin verrattuna sekä tilastollisin menetelmin hankittua tietoa tulevasta (Taulukko 5). Ennusteet perustuvat tieteellisiin menetelmiin ja näin ollen ovat yleensä helposti ymmärrettävissä ja tuettavissa myös yritysjohton puolelta. On myös tutkittu, että ennusteilla on positiivinen vaikutus yritysjohton tekemiin päätöksiin. Suurimmiksi ennustamisen haasteiksi voidaan lukea kysynnän epävarmuus, epätarkkojen ennusteiden riski, datassa olevat virheet, datan laadun varmistaminen, mallin valinta sekä se, miten määritellään, kuinka hyvä jokin malli on. Mallien vertailuun on kehitetty monia erilaisia menetelmiä. Menetelmien erot vaikuttavat siihen, miten niitä voidaan käyttää eri mallien ja datasettien vertailuun.

Taulukko 5 Ennustamisen hyödyt ja haasteet

Hyödyt	Haasteet
<ul style="list-style-type: none"> • Kustannussäästöt • Kilpailuetu • Tilastollisin ja tieteellisin menetelmin saatu tietoa tulevasta • Ymmärrys liiketoiminnan tulevasta suunnasta • Työkalu liiketoiminnan kehittämiseen • Motivoi yritysjohtoa 	<ul style="list-style-type: none"> • Toimintaympäristön epävarmuus • Epätarkat ennusteet • Datassa olevat virheet • Datan laatu • Sopivan mallin valinta • Ennusteiden hyvän laadun varmistaminen

Itse ennustusprosessi on monivaiheinen, joista jokainen on tärkeä hyvien ennusteiden takaamiseksi. Ennustusprosessi voidaan käsittää 5-vaiheisena ja se etenee datan keräämisestä, sen putsaamisesta ja jatkojalostuksesta, mallin rakentamiseen ja sen käyttöönottoon sekä mallin antamien ennusteiden arviointiin.

Toinen tutkimuskysymys oli:

2. Mitä erilaisia ennustemenetelmiä on olemassa ja mihin ne soveltuvat?

Ennustamista varten on tehty monia erilaisia malleja, joista jokaiselle on olemassa sopiva käyttökohde. Mallien suurimpina eroina voidaan pitää sitä, paljonko dataa mikäkin malli tarvitsee, kuinka yksinkertaisia ne ovat käyttää ja minkälaisia aikasarjoja mallien avulla voi ennustaa. Työssä tarkasteltiin muutamaa eri ennustemallia niin tasaisen kysynnän, trendiä mukailevan kysynnän sekä epäsäännöllisen kysynnän ennustamiseksi. Osa malleista on ollut olemassa jo pitkään, ja ne soveltuvat yleisesti suoraan käyttöön, mutta nykyään yhä useammin mallit on luotu johonkin tiettyyn tilanteeseen ja tietylle yritykselle. Tämän kehityksen on mahdollistanut koneoppimisen, tekoälyn ja neuroverkkojen yleistyminen, joiden avulla voidaan tehdä käytännössä malleja mihin tahansa tilanteeseen. Tällaisten mallien haasteena on kuitenkin, että mallien tekeminen on yleensä todella monimutkaista ja etenkin neuroverkkojen kohdalla voi olla mahdotonta nähdä, miten malli päättyy antamaansa ennusteeseen.

Työn perusteella voidaan sanoa, että ennustamisen avulla yritysten on mahdollista kehittää toimintaansa entistä tehokkaammaksi ja saavuttaa merkittäviä toiminnan kustannussäästöjä. Yritysten pitäisi ottaa ennustemallit yhä tiiviimmin osaksi päivittäisen ja pidempiaikaisen päätöksenteon tueksi. Ennustemallien mahdollisimman helpon käytön varmistamiseksi, ennustemallien pitäisi olla aina mahdollisimman yksinkertaisia, jotta niiden antamiin ennusteisiin on helppo luottaa ja niitä on helppoa käyttää liiketoiminnan tukena. Lisäksi yksinkertaiset ennustemallit antavat usein tarkempia ja parempia ennusteita kuin monimutkaiset ennustemallit.

LÄHTEET

- Adepu, A., Erdil, N.O. 2015, "Production planning based on demand forecasting", *IEOM 2015 - 5th International Conference on Industrial Engineering and Operations Management*, March 3-5, Dubai, United Arab Emirates. s. 1537-1542
- Aktas, N., Croci, E. & Petzemas, D. 2015, "Is working capital management value-enhancing? Evidence from firm performance and investments", *Journal of corporate finance.*, Vol. 30, nro 1, s. 98-113.
- Alstrøm, P. & Madsen, P. 1994, "Evaluation of forecast models used for inventory control during a product's life cycle: A simulation study", *International journal of production economics.*, Vol. 35, nro 1-3, s. 191-200.
- Appuhami, R.B.A. 2008, "The Impact of Firms' Capital Expenditure on Working Capital Management: An Empirical Study across Industries in Thailand", *International management review*, Vol. 4, nro 1, s. 8-21.
- Axsäter, S. 2015, *Inventory Control*, 3. painos Springer International Publishing, Cham, Switzerland. 268 s.
- Boada-Collado, P. & Martínez-de-Albéniz, V. 2020, "Estimating and optimizing the impact of inventory on consumer choices in a fashion retail setting", *Manufacturing & service operations management.*, Vol. 22, nro 3, s. 582-597.
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C. & Ljung, G.M. 2016, *Time Series Analysis: Forecasting and Control*, 5. painos, Wiley, Hoboken, New Jersey. 712 s.
- Cachon, G.P., Gallino, S. & Olivares, M. 2019, "Does adding inventory increase sales? Evidence of a scarcity effect in U.S. Automobile dealerships", *Management science*, Vol. 65, nro 4, s. 1469-1485.
- Campo, K., Gijsbrechts, E. & Nisol, P. 2003, "The impact of retailer stockouts on whether, how much, and what to buy", *International journal of research in marketing*, Vol. 20, nro 3, s. 273-286.

- Chaman, L.J. 2003, "Business forecasting in the 21st century", *The journal of business forecasting*, Vol. 22, nro 3, s. 3-6.
- Chang, O., Mosquera, G., Castillo, Z. & Zhinin-Vera, L. 2021, "Sales Forecast by Using Deep Rectifier Network", *Advances in Intelligent Systems and Computing*, Vol. 1288, s. 378-389.
- Choi, W.G. & Kim, Y. 2005, "Trade Credit and the Effect of Macro-Financial Shocks: Evidence from U.S. Panel Data", *The Journal of Financial and Quantitative Analysis*, Vol. 40, nro 4, s. 897-925.
- Croxton, K.L., Lambert, D.M., García-Dastugue, S.J. & Rogers, D.S. 2002, "The Demand Management Process", *The international journal of logistics management*, Vol. 13, nro 2, s. 51-66.
- Fabbri, D. & Klapper, L.F. 2016, "Bargaining power and trade credit", *Journal of corporate finance (Amsterdam, Netherlands)*, Vol. 41, s. 66-80.
- Filbeck, G. & Krueger, T.M. 2005, "An Analysis of Working Capital Management Results Across Industries", *American journal of business*, Vol. 20, nro 2, s. 11-20.
- Guerard, J. & Thomakos, D.D. 2004, "Naive, ARIMA, nonparametric, transfer function and VAR models: A comparison of forecasting performance", *International Journal of Forecasting*, Vol. 20, nro 1, s. 53-67.
- Hacker, R.S. & Hatemi-J, A. 2008, "Optimal lag-length choice in stable and unstable VAR models under situations of homoscedasticity and ARCH", *Journal of applied statistics*, Vol. 35, nro 6, s. 601-615.
- Hanke, J.E. & Wichern, D.W. 2014, *Business forecasting*, 9. painos, Pearson Education Limited, Harlow, England. 510 s.
- Hyndman, R.J. 2006a, "Another Look at Forecast Accuracy Metrics for Intermittent Demand", *Foresight: The International Journal of Applied Forecasting*, Vol. 4, s. 43-46.

- Hyndman, R.J. & Koehler, A.B. 2006b, "Another look at measures of forecast accuracy", *International Journal of Forecasting*, Vol. 22, nro 4, s. 679-688.
- Hyndman, R.J., Ord, J.K., Snyder, R. & Koehler, A.B. 2008, *Forecasting with Exponential Smoothing: The State Space Approach*, Springer-Verlag Berlin Heidelberg, Berlin, Heidelberg. 360 s.
- Kadochnikova, E.I., Erina, T.V. & Zainullin, S.G. 2019, "The use of arima model in forecasting accounts payable", *International Journal on Emerging Technologies*, Vol. 10, nro 2, s. 71-74.
- Kourentzes, N., Trapero, J.R. & Barrow, D.K. 2020, "Optimising forecasting models for inventory planning", *International Journal of Production Economics*, Vol. 225, s. 1-9.
- Küick, M. & Freitag, M. 2021, "Forecasting of customer demands for production planning by local k-nearest neighbor models", *International Journal of Production Economics*, Vol. 231, s. 1-22.
- Makridakis, S.G., Wheelwright, S.C. & Hyndman, R.J. 1997, *Forecasting: Methods and Applications*, 3. painos, Wiley. 656 s.
- Malmelin, N. 2021, *Radikaali uudistuminen: miten johtaa murroksessa*, 1. painos, Kauppakamari, Helsinki. 159 s.
- Mathai, A., Agarwal, A., Angampalli, V., Narayanan, S. & Dhakshayani, E. 2016, "Development of new methods for measuring forecast error", *International Journal of Logistics Systems and Management*, Vol. 24, nro 2, s. 213-225.
- Niskanen, J. & Niskanen, M. 2016a, *Tilinpäätösanalyysi*, 2. tarkistettu painos, Edita, Helsinki. 264 s.
- Niskanen, J. & Niskanen, M. 2016b, *Yritysrahoitus*, Edita, Helsinki. 460 s.
- Ord, K. & Fildes, R. 2013, *Principles of Business Forecasting*, 1. painos, Cengage Learning. 528 s.

- Palachy, S. 2019, *Stationarity in time series analysis*. [Verkkodokumentti]. [Viitattu 26.4. 2020]. Saatavilla <https://towardsdatascience.com/stationarity-in-time-series-analysis-90c94f27322>
- Petersen, M.A. & Rajan, R.G. 1997, "Trade Credit: Theories and Evidence", *The Review of financial studies*, Vol. 10, nro 3, s. 661-691.
- Psillaki, M. & Eleftheriou, K. 2015, "Trade Credit, Bank Credit, and Flight to Quality: Evidence from French SMEs", *Journal of Small Business Management*, Vol. 53, nro 4, s. 1219-1240.
- Rafuse, M.E. 1996, "Working capital management: an urgent need to refocus", *Management decision*, Vol. 34, nro 2, s. 59-63.
- Seppänen, H. 2011, *Yrityksen analysointi ja tilinpäätös*, Kauppakamari, Helsinki. 179 s.
- Schmidhuber, J. 2015, "Deep learning in neural networks: An overview", *Neural Networks; Neural Netw*, Vol. 61, s. 85-117.
- Shoensmith, G.L. & Pinder, J.P. 2001, "Potential inventory cost reductions using advanced time series forecasting techniques", *The journal of the Operational Research Society*., Vol. 52, nro 11, s. 1267-1275.
- Shumway, R.H. & Stoffer, D.S. 2006, *Time Series Analysis and Its Applications: With R Examples*, Springer Science+Business Media, LLC, New York, NY. 589 s.
- Song, Q. 2015, "Lessons learned and challenges encountered in retail sales forecast", *Industrial Engineering and Management Systems*, Vol. 14, nro 2, s. 196-209.
- Strand, S. 1999, "Forecasting the future: Pitfalls in controlling for uncertainty", *Futures*, Vol. 31, nro 3-4, s. 333-350.
- Tarkkala, M. 2020, Luento 3: Ennustaminen, luentokalvo, A35A00310 – Tuotantotalouden perusteet, Aalto-yliopisto, Espoo., Esitetty 6.5.2020
- Toor, T.P.S. & Dhir, T. 2011, "Benefits of integrated business planning, forecasting, and process management", *Business strategy series*., Vol. 12, nro 6, s. 275-288.

Woźniak, T. 2016, "Bayesian Vector Autoregressions", *Australian economic review*, Vol. 49, nro 3, s. 365-380.

Yan, W.Q. 2021, *Computational methods for deep learning: theoretic, practice and applications*, 1. painos Springer, Cham, Switzerland. 141 s.

LIITTEET

Liite 1. Kaavoja

Keskipoikkeaman kaava (Hyndman 2006a):

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (1),$$

missä

n on havaintojen lukumäärä

x_i on ennustettu arvo

y_i on todellinen arvo.

Keskineliövirheen kaava (Hyndman 2006a):

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (2),$$

missä

n on havaintojen lukumäärä

x_i on ennustettu arvo

y_i on todellinen arvo.

Prosentuaalisen keskipoikkeaman kaava (Hyndman 2006a):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - x_i}{y_i} \right| \quad (3),$$

missä

n on havaintojen lukumäärä

x_i on ennustettu arvo

y_i on todellinen arvo.

Suhteellisen poikkeaman kaava (Hyndman 2006a):

$$RAE = \frac{MAE}{MAE_n} \quad (4),$$

missä

MAE on käytetyn mallin keskipoikkeama

MAE_n on naiivin mallin keskipoikkeama.

Skaalatun keskipoikkeaman kaava (Hyndman 2006a):

$$MASE = \frac{MAE}{\frac{1}{n-1} \sum_{i=2}^n |y_n - y_{n-1}|} \quad (5),$$

missä

MAE on käytetyn mallin keskipoikkeama

$\frac{1}{n-1} \sum_{i=2}^n |y_n - y_{n-1}|$ on yksivaiheisen naiivin ennustemenetelmän keskipoikkeama ennustejaksoa edeltävältä jaksolta.

Kysynnän vakiomallin kaava (Axsäter 2015, s. 9):

$$x_t = a + \mathcal{E}_t \quad (6),$$

missä

a on jakson keskimääräinen kysyntä

\mathcal{E}_t on itsenäinen satunnaispoikkeama, jonka keskiarvo on nolla.

Eksponentiaalisen tasoituksen kaava kysynnän ennustamiseen (Hyndman et al. 2008, s. 13):

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha)\hat{y}_t \quad (7),$$

missä

α on tasoitusvakio

y_t on edellisen jakson toteutunut kysyntä

\hat{y}_t on edellisen jakson ennustettu kysyntä.

VAR mallin kaava kysynnän ennustamiseen (Woźniak 2016):

$$y_t = \mu + A_1 y_{t-1} + \dots + A_k y_{t-k} + u_t \quad (8),$$

missä

μ on N-vektori

$A_1 \dots A_k$ ovat autoregressiivisiä N x N muotoisia kerroinmatriiseja

u_t on virhetermi, joka noudattaa ehtoa:

$$u_t \sim N_N(0, \Sigma) \quad (9)$$

Liian suuren varaston täyttöasteen todennäköisyyden kaava (Shoesmith & Pinder 2001):

$$P_o = C_u / (C_o + C_u) \quad (10),$$

missä

C_u on tuotepuutteen yksikköhinta

C_o on ylimääräisen tuotteen varastonpitokustannus.

ARIMA malli (Axsäter 2015, s. 24):

$$\text{ARIMA}(p, d, q) \quad (11),$$

missä

p on autoregressiivisten parametrien määrä

d on differenssiaste

q on liukuvan keskiarvon parametrien määrä.