



TYÖPAPEREITA | WORKING PAPERS 325

# VAR-malli Suomen makrotalouden lyhyen aikavälin ennustamiseen\*

Miia Korhonen\*\*

---

\* Pro gradu -tutkielma 5.10.2018 Tampereen yliopisto

\*\* miiamk@mbnet.fi

---

## Tiivistelmä

Tutkimuksessa tarkasteltiin Suomen makrotalouden lyhyen aikavälin ennustamista rajoittamattomien vektoriautoregressiivisten mallien (VAR-mallien) avulla. Tavoitteena on hyödyntää rakennettuja VAR-malleja tutkimuslaitoksen lyhyen aikavälin ennustekäytössä syksyisin ja keväisin. Tutkimusta pohjustettiin selvittämällä talousennustamisen historiaa Suomessa sekä ennustamiseen liittyviä epävarmuustekijöitä. Lisäksi tarkasteltiin ennustemallityyppien keskeisiä piirteitä sekä syvennyttiin VAR- ja VARX-mallien rakenteeseen ja ominaisuuksiin. VAR-mallien estimointia varten kerättiin neljännesvuositason aineistoa vuodesta 1990 alkaen. Malleissa oli kolme valintakriteeriä: out-of-sample-ennusteiden tarkkuus keskineliövirheen neliöjuurella (RMSE) tai vuosikasvuasteen ennustevirheiden neliösummalla mitattuna, mallien makrotaloustieteellinen johdonmukaisuus impulssivasteiden ja Grangerin kausaalisuustestien avulla arvioituna sekä herkkyyshanalyysin tulokset. Kriteerien perusteella valituille malleille oli yhteistä vähäinen viiveiden määrä ja estimoinnin aloittaminen mahdollisimman varhaiselta periodilta. Kaikki valitut mallit sisälsivät seuraavat kolme muuttujaa: Suomen korjattu BKT, Euroopan unionin BKT ja Suomessa ja EU15:ssä työntekijälle maksettujen nimellisten kompensatioiden suhde. Näiden lisäksi mukana oli korkeintaan kaksi seuraavanlaista muuttujaa: yksityiset investoinnit sekä työvoimakustannukset työntekijää kohti. Mallien muuttaminen VAR-malleista VARX-malleiksi asettamalla Suomessa ja EU15:ssä työntekijälle maksettujen nimellisten kompensatioiden suhdemuuttujan eksogeeniseksi paransi mallien ennustetarkkuutta entisestään. Estimoidulla malleilla tehtiin ennusteita vuosille 2017 ja 2018. Ennusteita suoritettiin periodeista 2017Q1, 2017Q2 ja 2017Q4 alkaen. Periodeista 2017Q4 alkavissa ennusteissa keskimääräinen arvio Suomen bruttokansantuotteen kasvuasteelle on 3,1 prosenttia vuonna 2017 ja 1,8 prosenttia vuonna 2018.

Avainsanat: VAR-mallit, makrotalouden ennustaminen, lyhyen aikavälin ennustaminen, Suomen BKT:n ennustaminen.

# Sisällysluettelo

TIIVISTELMÄ.....	2
1. JOHDANTO.....	4
2. TALOUSENNUSTEIDEN LAATIMINEN.....	6
2.1. Talousennustaminen Suomessa.....	6
2.2. Talousennusteiden epävarmuus.....	7
3. VAR-ENNUSTEMALLIEN RAKENNE JA TUTKIMUKSEN AINEISTO.....	11
3.1. Ennustemallityyppien keskeiset piirteet.....	11
3.2. VAR-mallin estimointi.....	14
3.3. VAR-mallien estimointi epästationaarisilla ja differoiduilla aikasarjoilla.....	15
3.4. Eksogeeninen muuttuja VAR-mallissa.....	16
3.5. Aineisto.....	17
3.5.1 Muuttujat.....	17
3.5.2 Muuttujien korrelaatiokertoimet.....	21
4. VAR-MALLIEN VALINTAKRITEERIT.....	22
4.1. Ennusteiden tarkkuuteen perustuva mallin valinta.....	22
4.1.1. RMSE-vertailualgoritmi.....	24
4.1.2. Vuosikasvuasteeseen perustuva vertailualgoritmi.....	26
4.1.3 Vertailu ARIMA:an.....	28
4.2. Impulssivasteet.....	29
4.3 Grangerin kausaalisuustesti.....	34
4.4 Herkkyysanalyysi.....	37
5. EMPIIRISET TULOKSET VAR-MALLIEN VALINNASSA.....	41
5.1. Ennustetarkkuuteen perustuva mallin valinta.....	41
5.1.1. Viiveen pituuden valinta RMSE-algoritmillä.....	42
5.1.2 Estimoinnin aloitusperiodin valinta RMSE-algoritmillä.....	43
5.1.3 Muuttujien valinta RMSE-algoritmillä.....	44
5.1.4 Muuttujien valinta vuosikasvuasteeseen perustuvalla algoritmillä.....	45
5.1.4. Funktiomuoto: VAR-malleista VARX-malleiksi.....	47
5.2. Tulokset impulssivasteista.....	49
5.3. Tulokset Grangerin kausaalisuustesteistä.....	51
5.4. Tulokset herkkyysanalyyseistä.....	53
6. ENNUSTEET VUOSILLE 2017 JA 2018.....	57
6.1. VARX-mallien ennusteet.....	57
6.2. Ennusteiden luottamusvälit.....	58
6.2. Muut Suomea koskevat talousennusteet.....	59
7. YHTEENVETO.....	61
LÄHTEET.....	63
LIITTEET.....	71

# 1. JOHDANTO

Talouden lyhyen aikavälin ennustaminen on viimeisen vajaan kymmenen vuoden ajan ollut poikkeuksellisen epävarmaa. Suomen taloutta koetelleita shokkeja olivat muun muassa finanssikriisi, eurokriisi, paperiteollisuuden heikkeneminen ja Nokia-ilmiön nopea vaimeneminen. Shokit muovasivat talouden toimintaa niin merkittävästi, että voidaan puhua rakennemuutoksesta (Honkatukia, Tamminen & Ahokas 2014).

Rakennemuutos on heijastunut tutkimuslaitosten ennusteiden menestykseen. Palkansaajien tutkimuslaitoksen lyhyen aikavälin talousennusteissa on hyödynnetty EMMA-mallia (Lehmus 2007, 2009), joka on luonteeltaan uusklassisen ja keynesiläisen makromallin synteesi. Tämä malli ja laitoksen muut talousennusteissa käytetyt työkalut ovat olleet koetuksella. Vuosien 2011-2015 talousennusteet ennustivat BKT:n kasvun nopeaa piristymistä finanssikriisin jäljiltä. Kahden tai puolentoista vuoden päähän tehdyt BKT:n kasvuennusteet olivatkin systemaattisesti liian korkeita vuosien 2011-2015 välillä (Henriksson ym. 2012; Husa ym. 2013; Ilmakunnas ym. 2011a, 2011b, 2012, 2013, 2014a, 2014b, Tilastokeskus 2017). Vuoden 2015 keväällä ennustettu BKT:n kasvuaste vuodelle 2016 oli monen vuoden sarjassa ensimmäinen liian pessimistinen ennuste toteutuneeseen BKT:seen nähden (Ilmakunnas ym. 2015, Tilastokeskus 2017). Palkansaajien tutkimuslaitos ei ollut yksin ennustevirheidensä kanssa, sillä myös muista tutkimuslaitoksista esimerkiksi Valtiovarainministeriö, Suomen Pankki ja ETLA odottivat talouden kääntyvän finanssikriisin jäljiltä pian kasvuun. Kaikki edellä mainitut tutkimuslaitokset ennustivat vuodet 2011-2015 systemaattisesti yläkanttiin. (Valtiovarainministeriö 2016; Kontulainen 2017; Kotilainen 2017a.)

Talousennusteet vaikuttavat niin yksityisten kotitalouksien ja yritysten kuin myös julkisen vallan päätöksiin. Muun muassa investointipäätöksiensä taustalla on näkemys talouden tilasta tulevaisuudessa. Ennustevirheet eli kasvuaste-ennusteiden ja toteutuneiden kasvuasteiden erotukset tekevät päätöksenteosta epävarmaa ja potentiaalisesti epäoptimaalista. Epäoptimaalinen päätöksenteko johtaa taloudellisesti huonoihin ratkaisuihin.

Talousennustetta voidaan yrittää parantaa rakentamalla ennustetyössä käytettävän EMMA-mallin rinnalle toinen malli tukemaan ennustetyötä. Tässä tutkimuksessa eksogeenisista ja endogeenisista muuttujista koostuvan EMMA-mallin rinnalle rakennetaan endogeenisiä muuttujia sisältävä vektoriautoregressiivinen malli (VAR-malli). Eksogeenisiä muuttujia sisältävistä rakenteellisista malleista poiketen VAR-mallin parametreille ei tarvitse asettaa rajoituksia.

Muuttujien endogeenisuus mahdollistaa mallin rakentamisen ja estimoinnin silloin, kun muuttujien välinen syy-seuraussuhde ei ole ilmeinen. VAR-malli käyttää teoriaa sopivan muuttujajoukon valitsemiseen, mutta ei kunkin syy-seuraussuhteen erilliseen määrittelyyn (Allen & Fildes 2001). Tässä tutkimuksessa rakennettua VAR-mallia käytetään tukemaan Palkansaajien tutkimuslaitoksen kevään ja syksyn ennustetyötä. Tutkimuksesta on julkaistu aikaisempi versio Palkansaajien tutkimuslaitoksen työpaperisarjassa (ks. Korhonen 2018). Pro gradu -tutkimukseni täydentää työpaperia taustoittamalla talousennustamisen laatimista, laajentamalla ennustemallien ja erityisesti VAR-mallien teoriapohjaa sekä tarkastelemalla estimoituja ennustemalleja impulssivasteiden, Grangerin kausaalisuustestin sekä herkkyysanalyysin avulla.

Pro gradu -tutkielman luvussa 2 lukija johdatetaan aluksi talousennustamisen perinteeseen sekä talousennusteista käytävään keskusteluun. Luku 3 vertailee eri ennustemallityyppien ominaisuuksia sekä esittelee VAR- ja VARX-mallien estimointia. Luvussa esitellään myös tutkimusta varten kerätty aineisto erityispiirteineen. Luvussa 4 laaditaan kriteerit estimoitavien VAR-mallien valinnalle, ja luvussa 5 esitellään valintakriteerien tulokset. Valituilla malleilla tehdään luvussa 6 ennuste vuosille 2017 ja 2018. Luvussa 7 kootaan yhteen tutkimuksen johtopäätökset ja esitetään keinoja kehittää ennustemalleja entisestään.

## **2. TALOUSENNUSTEIDEN LAATIMINEN**

Sekä yksityinen että julkinen sektori tarvitsevat oman päätöksentekonsa tueksi tietoa tulevasta talouskehityksestä. Yksityisellä puolella erityisesti yritysten investointipäätökset ja kotitalouksien asuntoinvestoinnit sisältävät oletuksia siitä, millaiseksi kotimaan taloustilanne muovautuu lyhyellä (1–5 vuotta) ja keskipitkällä (5–10 vuotta), joskus myös pitkällä (yli 10 vuotta) aikavälillä. Julkinen sektori tarvitsee budjetin laatiakseen tietoa talouskehityksestä, saatavista verotuloista sekä katettavista julkisista menoista. Euroopan komissio edellyttää jäsenmaidensa seuraavan ja ennakoivan omaa talouspolitiikkaansa ja julkista talouttaan. (Kangasniemi 2017.) Useat Suomessa toimivat ennustelaitokset sekä yksityisen sektorin toimijat laativat talousennusteita palvelemaan tätä tarkoitusta. Tässä luvussa tarkastellaan talousennustamisen kehittymistä Suomessa, talousennustajia sekä ennustamiseen liittyviä epävarmuustekijöitä.

### **2.1. Talousennustaminen Suomessa**

Talousennustamisen juuria on mielekäästä tarkastella 1950-luvulta alkaen, jolloin kokonaistaloudellisia arvioita aloitettiin julkaista. Valtiovarainministeriö julkaisi ensimmäiset talousennusteensa vuonna 1953 budjettiesityksen yhteydessä (Keskisuomalainen 2008). Yksi 1960-luvun tunnetuimmista menetelmistä oli MEPLAMO (Medium-term Planning Model for the Finnish Economy), jolla tehtiin kokonaistaloudellisia kehitysarvioita ja arvioitiin erilaisten talouspoliittisten toimien vaikutuksia kehitysarvioihin (Mannermaa 1975). Vuonna 1962 perustetun Talousneuvoston työtä tukemaan perustettiin tutkimusjaosto 1963, joka selvitti kansantalouden kasvunäkymiä vuosina 1962–1967 (Lehto 2009). 1970-luvulla keskeisiä talousennustamisen toimijoita olivat mm. SITRA ja kokonaistaloudellisia keskipitkiä arvioita tehneet Talousneuvosto, Etlä ja Työväen Taloudellinen Tutkimuslaitos (TTT) (Wiio 1970; Lehto 2009). Lisäksi useat edellä mainituista laitoksista julkaisivat säännöllisesti 1–2 vuoden suhdanne-ennusteita (Etlä; Wiio 1970). Pellervon taloudellinen tutkimuslaitos liittyi talousennustajien joukkoon vuonna 1981 (Keskisuomalainen 2008).

Talousennusteiden kasvanut kysyntä ja tiedotusvälineiden huomio ovat aiheuttaneet sen, että ennusteprosessi on vuosikymmenien saatossa muuttunut läpinäkyvämmäksi ja avoimemmaksi. Esimerkiksi Suomen Pankin vain sisäisessä käytössä olleet ennusteet avautuivat yleisölle vuonna

1999. (Keskisuomalainen 2008; Pehkonen 2002.) Vastaavasti ennusteiden tarjonta on runsasta ja eri ennusteentekijöiden ennusteita on helppo vertailla keskenään. Ennusteiden läpinäkyvyys ei ole kuitenkaan täysin ulottunut ennustelaitosten käyttämiin malleihin. Ennustelaitokset vaikuttavat suhtautuvan ennustemalleihinsa paikoittain liikesalaisuuksien tavoin, minkä vuoksi osalla ennustelaitoksista ennustemallien yhtälöt ja aineisto ovat joko huonosti tai ei lainkaan saatavilla.

Tällä hetkellä keskeisimpiä Suomessa käytössä olevia ennustemalleja ovat muun muassa Palkansaajien tutkimuslaitoksen käyttämä EMMA, Suomen Pankin AINO 2.0, Etlan ETLA sekä Valtiovarainministeriön Kooma. Näistä EMMA on uusklassisen ja keynesiläisen makromallin synteesi, Aino 2.0 ja Kooma DSGE-malleja (dynamic stochastic general equilibrium) sekä ETLA uusklassinen synteesi (Lehmus 2007). Eri mallityyppien eroihin tutustutaan luvussa 3.

## **2.2. Talousennusteiden epävarmuus**

Talousennustaminen on saanut osakseen runsaasti kritiikkiä. Erityisesti taloudellisesti heikkoina aikoina tiedotusvälineissä on ilmaistu runsaasti epäluottamusta talousennustamista ja ennusteiden tarkkuutta kohtaan. Talousennustajia on syytetty kyvyttömyydestä ennustaa suhdannekäänteitä ja ennusteiden merkitystä on arvosteltu kärkkäästi (Pehkonen 2002; Vartiainen 2014).

Kaikille ennustelaitoksille yhteinen piirre näyttäisikin olevan, että ennustetarkkuus suhdannekäänteiden aikaan on ollut keskimääräistä selkeästi heikompaa. Esimerkiksi Palkansaajien tutkimuslaitoksen ennustevirheet ovat suurimmillaan äkillisen talouden taantumisen aikaan (Lehto 2009). Pahimmillaan niin sanottu yksinkertainen malli on ennustanut vähintään yhtä hyvin tai jopa paremmin kuin usean ennustelaitoksen kilpailevat mallit (Pehkonen 2002). Yksinkertaisessa mallissa on oletettu, että seuraavan vuoden ( $t+1$ ) kasvuaste on yhtä suuri kuin kaksi vuotta aiemmin toteutunut muutos ( $t-1$ ) (Pehkonen 2002).

Talousennustajien ennusteiden laadusta on tehty tieteellisiä tutkimuksia. Yleisesti ottaen näyttäisi siltä, että ennustajat eivät pysty ennakoimaan taloudellisia taantumia tai arvioimaan talouden kasvuasteita oikein talouden rakennemuutosten aikana (Dovern & Weisser 2011; Loungani 2001). Dovernin ja Weisserin (2011) eri maita tutkivassa vertailussa huomattiin, että valtaosalla maista ennusteet reagoivat rakenteellisiin muutoksiin viiveellä. Taantumien ennakoimisen epäonnistumisen taustalla katsotaan olevan joko puutteet ennustemalleissa, riittämättömät kannusteet ennakoimiseen tai heikko pääsy ajantasaiseen, luotettavaan tietoon (Loungani 2001).

Vakaassa taloustilanteessa talousennusteet ovat yleisesti ottaen harhattomia (Dovern & Weisser 2011), mutta tällöinkin ennustetyöhön liittyy joitakin huomionarvoisia tekijöitä. Kansainvälisissä vertailuissa valtaosalla talousennustajista on havaittavissa taipumusta tasoittaa BKT-ennusteitaan merkittävästi, kun taas muilla makrotalouden muuttujilla vastaavaa käytäntöä ei ole havaittavissa (Dovern & Weisser 2011). Lisäksi yhdenkään maan keskimääräiset ennusteet eivät olleet tehokkaita Agerin, Kapplerin ja Osterlohin (2009) tutkimuksen 12 OECD-maata käsittelevässä otannassa (Ager ym. 2009). Tehokkuudella tarkoitetaan, että ennusteissa käytetään hyödyksi kaikkea saatavilla olevaa aineistoa. Kuitenkin BKT:n kasvuasteen ennustamisessa onnistuneilla ennusteentekijöillä on taipumusta onnistua myös muiden makrotalouden muuttujien kasvuasteiden ennustamisessa (Dovern & Weisser 2011).

Ennustehorisontin merkityksestä ennusteen tarkkuuteen on niin ikään saatu tutkimustuloksia. Ilmenee esimerkiksi, että eri ennustelaitosten ennusteiden välinen jakauma kutistuu merkittävästi, kun ennustehorisontin pituus lähestyy nolaa (Dovern & Weisser 2011; Loungani 2001). Ennustehorisontin kasvaessa ennustetarkkuus heikkenee huomattavasti. Lounganin (2001) tutkimuksissa ilmeni, että ennustettaessa yli vuoden päähän talousennustajien ennusteet ovat korkeintaan niukasti parempia kuin yksinkertaiset ennusteet, joissa oletetaan ensi vuoden kasvun olevan yhtä suuri kuin kuluneen vuoden kasvu. Vastaavasti Agerin ym. (2009) analysoinneissa oli tuloksena, että useilla tutkimuksessa olleilla mailla ennusteet olivat harhaisia, kun ennustehorisontti oli yli 12 kuukautta pitkä. Ennusteiden epävarmuus kasvaa ennustehorisontin pidentyessä niin suuresti, että esimerkiksi Isiklarin ja Lahirin (2007) tutkimuksissa yli 18 kuukauden ennustehorisonteilla ennusteilla ei ole juurikaan enempää arvoa kuin yksinkertaisen ”ei muutosta kasvuasteessa” -mallin ennusteella. Arvellaan, että osa pitkän aikavälin kasvuennusteissa syntyvästä harhasta johtuu kasvun tasapainouran virheellisestä arvioinnista (Ager ym. 2009).

Taloutta arvioivat ja ennustavat tahot eivät kiistä ennusteidensa puutteellista kykyä ennakoida suhdannekäänteet. Ennustajien vastaus kritiikkiin pohjautuu tehokkaiden markkinoiden hypoteesiin, jossa osakkeiden hinnat hetkellä  $t$  heijastavat täydellisesti kaikkea kyseisenä hetkenä saatavilla olevaa tietoa, minkä vuoksi markkinoiden voittaminen uutta tietoa hyödyntämällä on mahdotonta. Vartiainen (2014) avaa hypoteesia sillä, että tulevaisuuden odotuksiin perustuvilla markkinoilla – rahoitus- ja osakemarkkinoilla, kiinteän omaisuuden markkinoilla ja raaka-aineiden futuurimarkkinoilla – kaikki odotusten muutokset heijastuvat markkinahintoihin välittömästi. Jos jokin ennustava taho esittäisi väitteen markkinatilanteen muuttumisesta siten, että odotukset markkinoilla muuttuisivat, hinnat sopeutuisivat välittömästi (Vartiainen 2014). Tämän vuoksi



suhdannekäänteeseen sisältävä ennuste on sisäisesti ristiriitainen ja suhdannekäänteeseen ennustaminen on mahdotonta (Pehkonen 2002; Vartiainen 2014; Huovari ym. 2009). Edellytyksenä edellä esitetylle päättelylle on kuitenkin oletus talousagenttien rationaalisuudesta. Osa tutkijoista ei myöskään jaa näkemystä tehokkaasti toimivista markkinoista (ks. esim. Malkiel 2003).

Argumentoidaan, että suhdannekäänteiden sijaan talousennustamisen roolina on antaa taloudesta kokonaiskuva, joka palvelee talousagenttien toimintaa normaalin taloustilanteen vallitessa (Vartiainen 2014; Haavio, Kortelainen & Kontulainen 2009). Tämän vuoksi ennustemallit rakennetaan siten, että niiden tuottamat ennusteet osuisivat keskimäärin oikeaan taloudelle tyypillisen kauden aikana (Haavio ym. 2009). Vaikka talousennusteet eivät onnistuisikaan ennakoimaan taluskriisiä, ne auttavat tunnistamaan talouden olemassa olevia ongelmia sekä talouteen lyhyellä aikavälillä todennäköisesti vaikuttavia tekijöitä (Huovari ym. 2009).

Osa tutkijoista puolustaa myös ennusteidensa lievää harhaisuutta vetoamalla tappion karttamiseen. Kahnemanin ja Tverskyn (1979) tappion karttamisen hypoteesin mukaisesti kiinnitetyn suuruinen negatiivinen tulema aiheuttaa suuremman tappion kokemuksen kun vastaavan suuruinen positiivinen tulema aiheuttaa hyötyä. Talousennustekontekstiin sovitettuna ennustettua alhaisemmaksi jäävä BKT:n kasvuaste aiheuttaisi talousennusteen käyttäjälle suuremman tappion kokemuksen kuin vastaavan suuruisella määrällä ennustetta korkeammalle ulottuva toteutunut BKT:n kasvuaste toisi hyötyä. Talousennusteiden käyttäjien tappiofunktiot voivat olla epäsymmetrisiä, jolloin talousennustajalla voi olla kannusteita omaksua ennusteen käyttäjän tappiofunktio. Tutkimuslaitosten ennustevirheiden harhaisuus voi siis ennustemallien epärationaalisuuden ohella syntyä siitä, että ennustajan tappiofunktio on epäsymmetrinen. Lanteen (2009) tutkimuksessa vertaillaan neljän suomalaisen ennustelaitoksen (VM, Etlä, PT ja PTT) tappiofunktioita. Tappiofunktio  $L(\alpha)$  on muotoa

$$L(\alpha) = [\alpha + (1 - 2\alpha) I(Y_{t+1} - f_{t+1} < 0)] | Y_{t+1} - f_{t+1} |.$$

Funktiossa  $Y_{t+1}$  viittaa muuttujan toteutuneeseen arvoon ja  $f_{t+1}$  muuttujan ennustettuun arvoon. Määritellään, että  $0 < \alpha < 1$  ja  $I(\cdot)$  on indikaattorifunktio, joka saa arvon yksi, kun ennustevirhe on negatiivinen. Ennustelaitoksen tappiofunktio on symmetrinen, jos  $\alpha = 0,5$ . Tappiofunktion symmetrisyyttä testataan Waldin testillä. (Lanne 2009.)

Vertailuryhmässä PT:llä, PTT:llä ja Etlalla on selvästi enemmän pessimistisiä kuin optimistisiä BKT:n kasvuasteen ennusteita. Waldin testissä kuitenkin vain PTT:n tappiofunktiossa  $\alpha$  poikkeaa 0,5:stä 95 prosentin luottamustasolla eli PTT:n tappiofunktio on epäsymmetrinen. (Lanne

2009.) Muiden ennustajien ennusteet ovat siis tilastollisesti harhattomia tarkasteltavalla aikavälillä (1982–2008).

Talousennustajien ennusteita arvioitaessa on myös huomioitava, että ennustejulkaisut sisältävät ainoastaan taloudellisten muuttujien odotusarvon tai todennäköisimmän arvon niiden jakaumien sijaan (Vartiainen 2014). Odotusarvo ja todennäköisin arvo voivat poiketa toisistaan erityisesti silloin, kun odotusarvojen jakauma on vino (Lehto 2009). Talousennuste kuvaakin numeerisesti vain yhtä mahdollista talouden skenaariota.

Tässä tutkimuksessa ennustemallin estimointi ja ennusteiden tulokset vastaavat talousennusteiden tekijöiden yleistä linjaa. Estimoidut mallit ovat paikoittain hyvinkin tarkkoja ennustamaan taloudellisten muuttujien kasvuasteita, mutta finanssikriisin aikana ennusteet poikkeavat merkittävästi toteutuneista kasvuasteista. Ennustemallien valinnassa on sovellettu symmetristä tappiofunktiota: mallia on rangaistu negatiivisesta ennustevirheestä yhtä paljon kuin vastaavan suuruisesta positiivisesta ennustevirheestä.

### **3. VAR-ENNUSTEMALLIEN RAKENNE JA TUTKIMUKSEN AINEISTO**

Edellä lukijaa on lyhyesti johdateltu talousennustamisen perinteeseen ja tarkoitukseen ottamatta lainkaan esille talousennusteiden tekemisen metodeja. On huomattava, että VAR-mallit ovat vain yksi mahdollinen keino ennustaa makrotalouden muuttujia. Tässä luvussa tutustutaan neljään erilaiseen mallityyppiin, joita voidaan käyttää talousennustetta tehdessä. Mallityyppien – DSGE, SSM (semi-structural model), VAR ja aikasarjamallit – ominaisuudet esitellään pääpiirteissään. Tämän jälkeen syvennyttään VAR-mallien estimointiin sekä stationaaristen ja epästationaaristen aikasarjojen käyttämiseen VAR-mallissa. VAR-mallien yhteydessä esitellään myös VARX-mallit, joissa perinteisesti endogeenisten muuttujien väliseen dynamiikkaan perustuvaan VAR-malliin tuodaan mukaan eksogeeninen muuttuja. Luvun lopussa esitellään ennustemalliin kerätty aineisto sekä tarkastellaan aineiston muuttujien välisiä yhteyksiä Pearsonin korrelaatioiden avulla.

#### **3.1. Ennustemallityyppien keskeiset piirteet**

Talousennustamisessa voidaan hyödyntää lukuisia erilaisia metodeja. Mallityypit poikkeavat toisistaan siinä, kuinka suuri talusteorian määrä on suhteessa empiriaan. Joidenkin mallien vahva teoreettinen rakenne kaventaa empirian liikkumatilaa, kun taas voimakkaasti empiirisissä malleissa teoreettinen perusta vain tukee mallin empiirisiä löydöksiä. Tavallisimmat taloudellisten aikasarjojen ennustamiseen käytettävät mallityypit voidaan asettaa teoriapainotteisimmasta alkaen seuraavaan järjestykseen: DSGE-mallit, SSM-mallit, VAR-mallit sekä puhtaat aikasarjamallit. Palkansaajien tutkimuslaitoksessa käytettävä EMMA-malli on DSGE-mallien uuskeynesiläisen haaran ja uusklassisen makromallin synteesi. Tämä tekee siitä hyvin teoriapainotteisen. Tässä tutkimuksessa estimoitava VAR-malli puolestaan edustaa empiriaan painottuvaa ennustemallityyppiä. Mallityyppien odotetaan täydentävän toisiaan tutkimuslaitoksen käytännön ennustetyössä. Seuraavaksi tutustutaan edellä esiteltyyn neljään ennustemallityyppiin yksi kerrallaan.

DSGE-mallit eli dynaamisen stokastisen yleisen tasapainon mallit pohjautuvat RBC-malleihin (real business cycle models), joiden perustana on mikrotaloudellinen teoria ja rationaaliset

odotukset. DSGE-malleissa mikrotaloudellinen perusta ja rakenne ovat löyhemmin kiinnittyneitä talousteorianaan kuin RBC-malleissa. Tämän lisäksi osa DSGE-malleista suhtautuu rationaalisten odotusten oletukseen varauksella. (Hjelm ym. 2015.) DSGE-mallit jakautuvat RBC-teoriaa painottaviin ja uuskeynesiläisyyttä painottaviin haaroihin (ks. esim. Cantore ym. 2010). RBC-teoriaan painottuvassa haarassa oletetaan yleensä täydellinen kilpailu ja joustavat hinnat, kun taas uuskeynesiläisten DSGE-mallien lähtökohtana on epätäydellinen kilpailu ja jäykät hinnat (Hjelm ym. 2015).

DSGE-mallien vahva taloustieteellinen perusta mahdollistaa niiden käyttämisen ennustetyön lisäksi politiikkamuutosten analysointiin. Yleiseen tasapainoon ja steady stateen pohjautuva malli on kuitenkin kankea tilanteissa, joissa talouden tasapainotila muuttuu seurauksena tuottavuuden kasvusta, reaalikoron muutoksesta tai jostain muusta eksogeenisestä trendistä. Malli on täten joustamaton lyhyellä aikavälillä. (Hjelm ym. 2015.)

SSM-mallit (semi-structural models / macroeconometric models) ovat DSGE-mallien tavoin rakenteellisia malleja, joskin SSM-malleissa mikrotalousteoreettinen perusta on DSGE-malleihin verrattuna kevyt. SSM-mallit esimerkiksi tarjoavat tarkasti määritellyn steady state -uran sijaan mahdollisuuden liikkuaan steady stateen. SSM-malleissa on yleensä enemmän yhtälöitä kuin DSGE-malleissa, minkä vuoksi ne ovat hyvin kattavia. SSM-mallit koostuvat usein heterogeenisten mallien ryhmistä, ja siksi on vaikeaa vertailla keskenään eri ennusteentekijöiden SSM-malleihin pohjautuvia ennusteita. Näin ei ole esimerkiksi DSGE-mallien ennusteiden tapauksessa. (Hjelm ym. 2015.)

DSGE-mallien ja SSM-mallien kaltaisissa rakenteellisissa malleissa muuttujat jaotellaan endogeenisiin ja eksogeenisiin muuttujiin. Tällöin muuttujien väliset kausaalisuhteet on määriteltävä ennalta. Mallin identifioimisen takaamiseksi mallin yhtälöiden parametreja joudutaan usein rajoittamaan, vaikka tämä ei olisi teoreettisesti perusteltua. (Gujarati & Porter 2009, 784.)

VAR-mallit soveltuvat ennustekäyttöön silloin, kun tarkasteltavassa prosessissa muuttujat ovat toisistaan keskenään riippuvaisia ja kun hetken  $t$  arvoja voidaan selittää edellisten  $t-i$  periodien arvoilla (Pecican 2010). VAR-mallissa kaikki muuttujat asetetaan endogeenisiksi, ja kutakin muuttujaa selitetään sen omilla ja muiden muuttujien viiveillä. Tällä tavoin voidaan välttyä perusteettomilta parametrirajoituksilta. Kun muuttujien välillä on dynaamisuutta ja simultaanisuutta, niiden jakaminen endogeenisiin ja eksogeenisiin tuo estimointiin harhaa (Sims 1980). Koska muuttujien endogeenisuus synnyttää niiden välille dynaamista interaktiota, VAR-

mallin katsotaan kuvaavan taloudellisia ilmiöitä totuudenmukaisemmin kuin rakenteellisten mallien (Pecican 2010). Toisin kuin rakenteellisissa malleissa, VAR-malleja estimoitaessa muuttujia ei myöskään tarvitse asettaa järjestykseen Granger-kausalisuuden suhteen. Muuttuja  $y_2$  on Granger-kausallinen muuttujan  $y_1$  suhteen, jos muuttujan  $y_2$  hetken  $t-1$  arvolla voidaan ennustaa muuttujan  $y_1$  hetken  $t$  arvoa. Granger-kausalisuudella ei voida kuitenkaan osoittaa muuttujien välistä aitoa kausalisuutta, vaan kausalisuutta ennustamismielessä (ks. esim. Granger 1969). Toisin kuin DSGE-mallit, VAR-mallit ovat erittäin joustavia muuttujavalinnan suhteen (Hjelm ym. 2015).

VAR-malleissa on muutamia olennaisia heikkouksia. Vaikka VAR-malleja estimoitaessa muuttujavalintaa perustellaan teorian keinoin, estimointi ei DSGE- ja SSM-malleista poiketen ole teorialähtöistä (Allen & Fildes 2001; Pecican 2010). Mallin rakentaminen toimii ennemminkin aineiston ehdoilla. Lisäksi pitkistä viiveistä syntyvä parametrien suuri määrä vähentää mallin vapausasteita merkittävästi (Pecican 2010).

VAR-mallien heikkoudeksi voidaan laskea Lucasin (1976) kritiikin mukaisesti se, että kiinnitetyn poliittisen järjestelmän vallitessa estimoitu malli on riippuvainen kyseisen järjestelmän säilyvyydestä. Toisin sanoen mallin parametrit ovat alttiita muutokselle, kun poliittiset käytänteet muuttuvat. Sen sijaan DSGE-mallit välttävät Lucasin kritiikin teorialähtöisyytensä vuoksi (Hjelm ym. 2015). VAR-malleja pidetään ongelmallisina myös aikasarjojen stationaarisuuteen liittyvien vaatimusten vuoksi. Stationaarisia ja epästationaarisia aikasarjoja käsitellään luvussa 2.3.

Ennustemalleista puhtaat aikasarjamallit ovat empiriaan eniten painottuvia malleja. Eräs tavallisimmista puhtaista aikasarjamalleista on ARIMA (autoregressive integrated moving average). ARIMA-mallin rakentaminen perustuu yksittäisen aikasarjan todennäköisyyksiin liittyviin ominaisuuksiin (Gujarati & Porter 2009, 774–775). Toisin sanoen se ei hyödynnä talousteoriaa, joka selittää eri muuttujien välisiä suhteita. Mallin muuttujalle ennustamat arvot riippuvat yksinomaan muuttujan menneistä arvoista sekä virhetermistä. (ks. esim. Box & Pierce 2010.) Usein ARIMA:a tai muita puhtaita aikasarjamalleja ei käytetä ennustemalleina sinänsä, vaan ne toimivat referenssinä ensisijaiselle ennustemallille. Tässäkin tutkimuksessa kustakin VAR-mallin muuttujasta estimoitua ARIMA-mallia käytetään vertailukohtana, kun estimoitujen VAR-mallien ennustetarkkuutta arvioidaan. ARIMA:lla ennustamiseen palataan alaluvussa 4.1.3.

### 3.2. VAR-mallin estimointi

VAR-malli estimoidaan asettamalla kaikki mallin muuttujat endogeenisiksi ja selittämällä kutakin muuttujaa kaikkien mallissa olevien muuttujien viiveillä. Esimerkiksi kahden muuttujan kahden viiveen VAR-malli VAR(2) on muotoa

$$\begin{aligned} y_{1t} &= a_{10} + b_{11,1} y_{1,t-1} + b_{12,1} y_{2,t-1} + b_{11,2} y_{1,t-2} + b_{12,2} y_{2,t-2} + u_{1t} \\ y_{2t} &= a_{20} + b_{21,1} y_{1,t-1} + b_{22,1} y_{2,t-1} + b_{21,2} y_{1,t-2} + b_{22,2} y_{2,t-2} + u_{2t} \end{aligned}$$

$$\begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \end{bmatrix} + \begin{bmatrix} b_{11,1} & b_{12,1} \\ b_{21,1} & b_{22,1} \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \end{bmatrix} + \begin{bmatrix} b_{11,2} & b_{12,2} \\ b_{21,2} & b_{22,2} \end{bmatrix} \begin{bmatrix} y_{1,t-2} \\ y_{2,t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

(Pecican 2010). Mallin matriisimuotoa voidaan myös tiivistää seuraavasti:

$$Y_t = A + B_1 Y_{t-1} + B_2 Y_{t-2} + U_t \quad ,$$

missä isot kirjaimet viittaavat edellä esitettyihin matriiseihin ja vektoreihin.

Yleisessä tapauksessa VAR-mallissa on  $k$  muuttujaa ja  $p$  viivettä. VAR-mallin kunkin muuttujan  $y_k$  viiveillä  $t-p$  on vaikutus kunkin muuttujan  $y_k$  nykyhetken  $t$  arvoihin. Yhtälöryhmä on muotoa:

$$Y_t = A + B_1 Y_{t-1} + B_2 Y_{t-2} + \dots + B_p Y_{t-p} + U_t \quad , \text{ missä}$$

$Y_t, \dots, Y_{t-p} = k \times 1$  endogeenisten muuttujien vektorit

$A = k \times 1$  vakiovektori

$B_1, \dots, B_p = k \times k$  parametrimatriisit

$U =$  virhetermien  $k \times 1$  vektori. (Pecican 2010.)

Virhetermien  $u_t$  oletetaan olevan valkoista kohinaa,  $u_t \sim N(0, \Sigma_u)$  kaikilla  $t$  (Lütkepohl 2005, 16; Pecican 2010). Virhetermit oletetaan autokorreloimattomiksi  $E(u_t, u'_s) = 0$  kaikille  $s \neq t$  (Lütkepohl 2005, 13; Pecican 2010). Toisin sanoen ennusteissa ei esiinny systemaattista harhaa. Lisäksi oletetaan VAR-yhtälöryhmän stabiilisuus, jota tutkitaan  $k \times k$  identiteettimatriisin (merkitään  $I_k$ ) sekä  $B_1, \dots, B_p$  parametrimatriisien avulla. VAR-yhtälöryhmä on stabiili, jos

$$\det(I_k - B_1 z - B_2 z^2 - \dots - B_p z^p) \neq 0, \quad \text{kun } |z| < 1 \quad .$$

Toisin sanoen determinanttiyhtälön nollakohtien ratkaisussa tuntemattoman muuttujan  $z$  juurten on oltava itseisarvoltaan suurempia kuin 1. (Lütkepohl 2005, 15–17.)

### 3.3. VAR-mallien estimointi epästationaarisilla ja differoiduilla aikasarjoilla

Perinteisesti VAR-mallien estimointi tehdään stationaarisille aikasarjoille. Stationaarisella sarjalla tarkoitetaan sellaista aikasarjaa, jonka ensimmäinen ja toinen momentti eli odotusarvo ja varianssi ovat äärellisiä ja vakioita yli ajan. Stationaarisen sarjan autokovarianssit riippuvat vain kahden vektorin  $y_t$  ja  $y_{t-h}$  välisestä etäisyydestä  $h$  (viiveen pituudesta), eivät ajasta  $t$  (Lütkepohl 2005, 24). Stationaarisen aikasarjan odotusarvon pysyminen vakiona tarkoittaa, että aikasarja pyrkii palaamaan keskiarvoonsa pitkällä aikavälillä.

Laajennetulla Dickey–Fullerin yksikköjuuritestillä tutkitaan, kuinka todennäköisesti tarkasteltavana oleva aikasarja palautuu keskiarvoonsa pitkällä aikavälillä. Olkoon aikasarja muotoa

$$y_t = \alpha + \rho y_{t-1} + e_t ,$$

jossa virhetermi  $e_t \sim N(0, \delta^2)$ . Nollahypoteesina on aikasarjan epästationaarisuus eli

$$H_0: (\alpha, \rho) = (0, 1) .$$

Epästationaarinen sarja voidaan muuttaa stationaariseksi differoimalla alkuperäinen aikasarja. Tällöin yksikköjuuritesti suoritetaan uudestaan differoidulle sarjalle stationaarisuuden varmistamiseksi. (Dickey & Fuller 1981.)

Tiedeyhteisö ei ole yksimielinen siitä, millaisia toimenpiteitä yksikköjuuritestien tulosten johtopäätöksistä tulisi seurata. Kun ekonometrissa mallia rakennetaan, muuttujien stationaarisuus on perinteisesti ollut ehtona, jotta parametriestimaatit olisivat luotettavia. Tällöin ohjeena on differoida epästationaarinen aikasarja riittävän monta kertaa yksikköjuuren poistamiseksi. Sarjat differoimalla voidaan eliminoida näennäisregression riski, mutta samalla menetetään tietoa epästationaaristen muuttujien tasojen pitkän aikavälin suhteista.

Allen ja Fildes (2001) suosittelevat estimoimista tasoissa yksikköjuurista riippumatta. Clementsin ja Hendryn (1995) tutkimuksissa tasomallin tasoennusteet olivat RMSE-kriteereillä mitattuna tarkempia kuin differenssimallin tasoennusteet. Vastaavasti differenssimallin differenssiennusteiden RMSE:t olivat pienempiä kuin tasomallin differenssiennusteiden RMSE:t (Clements & Hendry 1995).

Lin ja Tsay (1996) argumentoivat differenssimuotoisen VAR-mallin puolesta. Heidän tuloksissaan differenssimuotoisen mallin ennusteet menestyivät paremmin kuin tasomuotoisen mallin ennusteet, erityisesti korkeintaan 10 periodin ennusteissa. Yhteisintegroitu tasomuotoinen VAR-malli menestyi suhteellisesti paremmin kuin differoitu stationaarinen VAR-malli vasta silloin, kun ennusteperiodeja oli 15 tai enemmän (Lin & Tsay 1996). Hendryn (1996) (Allen & Fildes 2001

mukaan) tuloksissa differenssimuotoinen malli on robusti rakennemuutoksille, mikä saattaa selittää differenssimuotoisten mallien suhteellisen hyvää menestystä (Allen & Fildes 2001).

Tässä tutkimuksessa rakennettuja VAR-malleja käytetään lyhyen aikavälin ennustamiseen kuuden tai kahdeksan vuosineljänneksen päähän. VAR-mallin perinteitä sekä Linin ja Tsayn (1996) tutkimustuloksia noudattaen tutkimuksen VAR-mallit on estimoitu stationaarisista muuttujista.

### 3.4. Eksogeeninen muuttuja VAR-mallissa

Toisinaan VAR-mallin endogeenisten muuttujien yhtälöryhmään vaikuttaa VAR-mallin ulkopuolelle jäävä muuttuja. Toisin sanoen on olemassa eksogeeninen muuttuja, joka vaikuttaa ainakin osaan VAR-mallin muuttujista tilastollisesti merkittävästi, mutta johon VAR-mallin endogeeniset muuttujat eivät puolestaan vaikuta. Tällaista mallia kutsutaan VARX(p,s)-malliksi, jossa p on endogeenisten muuttujien viiveiden määrä ja s on eksogeenisten muuttujien viiveiden määrä. (ks. esim. Lütkepohl 2005, 387–388.)

VARX-mallissa endogeeniset muuttujat määräytyvät mallin sisällä, kun taas eksogeeniset muuttujat tulevat malliin ulkopuolelta. Alla on esimerkkinä kahden endogeenisen ja yhden eksogeenisen muuttujan VARX(3,1), jossa on kolme endogeenista ja yksi eksogeeninen viive:

$$\begin{bmatrix} y_{1t} \\ y_{2t} \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \end{bmatrix} + \begin{bmatrix} b_{11,1} & b_{12,1} \\ b_{21,1} & b_{22,1} \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \end{bmatrix} + \begin{bmatrix} b_{11,2} & b_{12,2} \\ b_{21,2} & b_{22,2} \end{bmatrix} \begin{bmatrix} y_{1,t-2} \\ y_{2,t-2} \end{bmatrix} + \begin{bmatrix} b_{11,3} & b_{12,13} \\ b_{21,3} & b_{22,3} \end{bmatrix} \begin{bmatrix} y_{1,t-3} \\ y_{2,t-3} \end{bmatrix} + \begin{bmatrix} b_{13} \\ b_{23} \end{bmatrix} [x_{t-1}] + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

(Lütkepohl 2005, 387–388.)

Eksogeeninen muuttuja x voi määräytyä esimerkiksi menneistä arvoista:

$$x_t = a_x + c_1 x_{t-1} + \dots + c_q x_{t-q} + v_t, \text{ missä}$$

a on vakio

(c<sub>1</sub> ...c<sub>q</sub>) parametriestimaatteja

v<sub>t</sub> = virhetermi

(ks. esim. Lütkepohl 2005, 401).

Empiirisessä tutkimuksessa voidaan joissain tapauksissa myös hyödyntää muuttujan x arvoista saatavilla olevaa a priori -tietoa. Jos muuttujana x on esimerkiksi palkkataso tai



nimelliskorko, ja seuraavan vuoden palkkaneuvotteluiden tuloksesta tai EKP:n linjasta korkotason suhteen päästään kohtalaiseen varmuuteen, voidaan eksogeenisen muuttujan arvot syöttää suoraan malliin. Tämä tarjoaa VARX-mallille joustovaraa, sillä perinteisesti VAR-malli ei voi lainkaan huomioida ennusteissa a priori saatua informaatiota. Toisaalta eksogeenisen muuttujan käyttäminen vaatii  $x$ :n arvon määrittelemistä mallin ulkopuolella toisen mallin tai edellä mainitun a priori -tiedon avulla, mikä voi vähentää VARX-mallin käytön yksinkertaisuutta.

### **3.5. Aineisto**

Edellä on käsitelty VAR-mallien taustaa sekä mallissa käytettävien muuttujien muodon valintaa stationaarisuuden ja eksogeenisuuden suhteen. Menestyäkseen ennustemalli vaatii muodon valinnan ohella onnistuneen muuttujavalinnan. VAR-mallin muodon johdosta on ensinnäkin keskeistä, että muuttujat ovat keskenään riippuvaisessa vuorovaikutussuhteessa. Toisena tavoitteena on rakentaa riittävän yksinkertainen ja selkeä malli, joka samalla kuvastaa todellista tiedon generointiprosessia. Kolmanneksi, jotta ennustemallia voitaisiin hyödyntää tutkimuslaitoksen rutiininomaisessa käytössä, on mallissa käytettävien muuttujien oltava kerättävissä kohtuullisen vaivattomasti ja lyhyellä viiveellä. Mallin aineisto kerättiin nämä tavoitteet huomioiden. Alla esitellään ensin VAR-mallia varten kerätyt muuttujat. Tämän jälkeen tarkastellaan muuttujien välisiä suhteita Pearsonin korrelaatioiden avulla.

#### **3.5.1 Muuttujat**

Tutkimuksen aineisto kerättiin aina vuodesta 1990 alkaen, jotta estimointia oli mahdollista tehdä tarpeen vaatiessa myös pitkillä viiveillä. Lütkepohlin (2005, 534–535) suosituksen mukaan estimoitavien parametrien määrä (muuttujamäärän ja viiveen pituuden tulo) ei saa ylittää havaintojen lukumäärän neliöjuurta. Mikäli parametrien lukumäärä suhteessa aikasarjan pituuteen h nousee suureksi, VAR-analysissä saadut parametriestimaatit voivat olla epätasällisiä ja epävarmoja. Jos estimoitavia parametreja on havaintoihin nähden liikaa, ennustetarkkuus keskimäärin heikkenee. (Lütkepohl 2005, 5–6, 193.)

Keräämällä neljännesvuosiaineistoa aikaväliltä 1990–2016 havaintoja kertyi yhteensä  $27 \times 4 = 108$ , jolloin estimoitavien parametrien suositeltu enimmäismäärä on  $\sqrt{108} \approx 10$ . Havaintojen

lukumäärää olisi voitu nostaa käyttämällä kuukausitason aineistoa, mutta kuukausiaineistot olivat saatavissa vain harvoille muuttujille. Osa tärkeäksi osoittautuneista muuttujista oli puolestaan saatavilla vain vuositason aineistona, mistä ne piti edelleen hajottaa neljännesvuositasolle sopivan referenssisarjan avulla. Hajottamiseen käytettiin Chow-Linin (Chow & Lin 1971) ja Dentonin (Denton 1971) menetelmiä.

Kuten ennustetarkasteluissa käy myöhemmin ilmi, aineiston pitäminen mahdollisimman laaja-alaisena antoi tarkimmat tulokset pienilläkin viive- ja muuttujamäärillä.

Muuttujien keskeiset ominaisuudet on koottu liitteeseen 1. Kerättyjä muuttujia olivat bruttokansantuote (*bkt*), kulutus (*c*), investoinnit (*i*), työttömyysaste (*u\_seas*), Euroopan unionin BKT (*bkt28*), kuluttajahintaindeksi (*khi90*), inflaatio (*inf*), julkiset investoinnit (*gi*) ja julkinen kulutus (*gc*), kolmen kuukauden korko (*r*) sekä muutama kilpailukykyä ja kansainvälistä taloutta kuvaava muuttuja. Kilpailukykyä heijastavia muuttujia edustavat Suomen työvoimakustannukset työntekijää kohti (*lcost*) sekä nimellinen kompensatio työntekijää kohti Suomessa jaettuna EU15:n vastaavalla luvulla (*fi\_eu15*). Työvoimakustannuksiin on sisällytetty työnantajan maksamat palkat ja palkkiot sekä sosiaaliturvamaksut.

Eurostatin määritelmän mukaan nimellisillä kompensatioilla tarkoitetaan kaikkea työnantajan rahalla tai muilla vastikkeilla työntekijälle osoittamaa korvausta tehdystä työstä (Ameco 2017). Se kattaa kokonaan kuluerät ”Palkka D.11” ja ”Työnantajan sosiaaliturvamaksut D.12” (Ameco 2017). Vaikka Suomen työvoimakustannukset työntekijää kohti ja Suomen nimellinen kompensatio työntekijää kohti (*ncpe\_fi*) ovat keskenään läheisiä muuttujia, kerätyssä aineistossa niiden differenssien välinen korrelaatio on 0,59 aikavälillä 1990–2016. Lisäksi Suomen nimellistä kompensatiota työntekijää kohti ei ole käytetty estimoinneissa muuttujana sinänsä, vaan Suomen nimelliset kompensatit *ncpe\_fi* on suhteutettu Euroopan unionin viidentoista ydinmaan nimellisiin kompensatioihin *ncpe\_eu15*. Tätä perustellaan sillä, että Euroopan unionin 15 ydinmaata ovat Suomen tärkeimpiä kilpailijoita kansainvälisillä markkinoilla. Nimellisten kompensatioiden osamäärämuuttujan *fi\_eu15* korrelaatio Suomen työntekijää kohti laskettujen työvoimakustannusten kanssa on vain 0,10.

Kansainvälisten markkinoiden muuttujista ulkomaankaupan kontribuutio laskettiin erotuksena tuonnin ja viennin BKT-osuuksien ja niiden muutosten tuloista. Lisäksi VAR-mallille rakennettiin vienti- ja valuuttakorimuuttujat. Vientikori on Suomen suurimpien vientikumppaneiden euromääräisillä vientiosuuksilla painotettu BKT-indeksi. Se kuvaa kansainvälisen talouden

kehitystä Euroopan unionimaiden BKT-muuttujan rinnalla.

Valuuttakori on Suomen suurimpien vientikumppaneiden euromääräisillä vientiosuuspainoilla tulosummattu Suomen 29 suurimman kauppakumppanin valuuttakurssi-indeksi. Kunkin maan kotimaisen valuutan markkaurssi on kerätty neljännesvuoden keskiarvona ja kurssikehitys on indeksoitu perusvuodelle 2010. Suomen valuutan vahvistuminen näkyy indeksin kasvuna. Vuodesta 1999 alkaen Suomen ja usean Suomen kauppakumppanin siirtyessä euroon kurssikehitys on muunnettu siten, että EMU:un kulloinkin kuuluvien maiden välinen valuuttakurssi säilyy kiinteänä. Suomen 29 suurimman vientimaan indeksoidut kurssit on painotettu maiden vientiosuuksien mukaan, jolloin on saatu yksi valuuttakurssikehitystä kuvaava indeksi. Sekä vientikorissa että valuuttakorissa on vuosittain vaihtuvien painojen sijaan käytetty vuosien 2010–2016 keskimääräisiä vientipainoja. Näin on tehty siitä huolimatta, että Suomen suurimpien kauppakumppanien kokoonpano ja viennin suhteelliset osuudet ovat kehittyneet paljon vajaan kolmenkymmenen vuoden aikana. Esimerkiksi Venäjän viennin suhteellinen osuus on laskenut merkittävästi (Euro ja Talous 2015). Vaihtuvilla painoilla vienti- ja valuuttakorimuuttujaa olisi saatu tarkennettua, mutta prosessi olisi ollut työläs. Lisäksi suurimpien kauppakumppanien kokoonpanon muutos pitkällä aikavälillä toisi muuttujan rakentamiseen epävarmuutta.

Lopuksi BKT-sarjan rinnalle laskettiin korjattu BKT, jossa alkuperäisestä BKT-sarjasta on poistettu Nokian vaikuttavimpina vuosina BKT-sarjaa volatiiliksi muuttanut Nokian ylimääräinen arvonlisäys. Ylimääräinen arvonlisäys on syntynyt Nokian tilinpidosta, jossa Nokian ulkomailla syntyneitä voittoja ja tappioita kotoutettiin Suomeen sopeuttamalla kirjanpidon kulueriä ”kauppatavaroiden ostot” sekä ”aine-, tarvike- ja tavaraostot”. Toimenpide synnytti liioiteltua vaihtelua Suomen bruttokansantuotteeseen ja tuottavuuteen. (Lehto, Lähdemäki & Kiema 2015.) Kun BKT-sarjasta poistetaan ylimääräinen arvonlisäys, saadaan muuttuja, joka kuvaa reaalityaloutta täsmällisemmin kuin alkuperäinen BKT-sarja. Alkuperäisen BKT-sarjan ja korjatun BKT:n arvot poikkeavat toisistaan vuosien 1999–2014 välisenä aikana siten, että finanssikriisiä edeltävänä aikana korjatun BKT:n arvot ovat BKT-arvoja alhaisemmat kun taas kriisin jälkeen korjatun BKT:n sarja on BKT-sarjaa korkeammalla. Korjattu BKT piirtää siis suhteellisesti tasaisemman BKT-uran kuin alkuperäinen BKT-sarja, joskin muuttujien differenssien välinen korrelaatio vuosien 1999–2014 aikana on 0,96.

Valtaosa aikasarjoista kerättiin kausitasoitettuina reaali-innoin, koska muuttujien kehitystä tarkasteltiin volyyymeissa. Kilpailukyvyyn muuttujat on sen sijaan kerätty nimellishinnoin.

Liitteeseen 1 on kerätty kunkin muuttujan arvostusperiaate sekä tieto sen kausitasoituksesta, lähteestä ja stationaarisuudesta. Lisäksi liitteeseen 2 on kerätty muuttujien kuvaajat, joista voidaan tehdä arvioita sarjojen yksikköjuurista. Aikasarjojen yksikköjuurihypoteeseja testataan systemaattisesti laajennetuilla Dickey–Fullerin yksikköjuuritestillä. Tulokset muuttujien tasojen ja differenssien yksikköjuuritestien p-arvoista on taulukoitu liitteeseen 3. Tämän luvun yksikköjuuritestien ja korrelaatiokerrointen tarkastelussa on hyödynnetty kunkin muuttujan alkuperäisen aikasarjan differenssiä (d), kun taas luvussa 5 VAR-mallit on estimoitu logaritmin differenssejä (dlog) käyttäen. Yksikköjuuritesteissä yhtälöihin on sisällytetty vakio, mutta ei trendiä. Testiyhtälöiden differenssien viivepituus on valittu Schwarzin kriteerein. Työttömyysaste ja  $fi\_eu15$  osoittautuvat stationaarisiksi tasoissa, kun taas esimerkiksi BKT, investoinnit, työvoimakustannukset Suomessa sekä valuuttakori ovat differenssistationaarisia.

Jatkossa muuttujiin viitataan seuraavilla lyhenteillä:

BKT	<i>bkt</i>
korjattu BKT	<i>bktadj</i>
kulutus	<i>c</i>
investoinnit	<i>i</i>
kausitasoitettu työttömyysaste	<i>u_seas</i>
kuluttajahintaindeksi	<i>khi90</i>
Euroopan unionin BKT	<i>bkt28</i>
Suomen työvoimakustannukset työntekijää kohti	<i>lcost</i>
Suomen ja EU15:n nimellisten kompensaatioiden suhde	<i>fi_eu15</i>
valuuttakori	<i>cur29</i>
vientikori	<i>bkt29</i>
kolmen kuukauden korko	<i>r</i>
ulkomaankaupan kontribuutio	<i>trcontr</i>
julkiset kulutusmenot	<i>gc</i>
julkiset investoinnit	<i>gi</i>

julkiset menot

*g*

inflaatio

*inf.*

### **3.5.2. Muuttujien korrelaatiokertoimet**

Aloitetaan muuttujien välisten suhteiden tarkastelu selvittämällä muuttujien väliset korrelaatiokertoimet. Lisäksi tarkastellaan kunkin muuttujan BKT-sarjan ja korjatun BKT-sarjan kanssa lasketun korrelaatiokertoimen kehittymistä.

Pearsonin korrelaatiokerroin on tunnusluku, joka kuvaa muuttujien välisen lineaarisen yhteyden suuruutta välillä  $[-1, 1]$ . Ennustemalleissa korrelaatiokertoimien avulla voidaan selvittää, kuinka paljon epävarmuutta kukin mallin muuttuja tuo mallin ennusteisiin. Tämän vuoksi Pearsonin korrelaatiokertoimia voidaan hyödyntää myös herkkyysanalyysissä. (Gardner ym. 1981 Hambyn 1994 mukaan.) Korrelaatiokertoimien kehityksessä ajan myötä tapahtuvien muutosten arvellaan tuovan parametriestimaatteihin epävarmuutta.

Otetaan tarpeen vaatiessa differenssit muuttujien alkuperäisistä aikasarjoista yksikköjuuritestien tulosten perusteella ja tarkastellaan korrelaatioita stationaaristen sarjojen välillä. Stationaaristen aikasarjojen väliset korrelaatiot ovat ymmärrettävästi merkittävästi pienemmät kuin epästationaaristen aikasarjojen korrelaatiot. Ristikkäiskorrelaatiot on kerätty liitteeseen 4. Muuttujia rajatessa jätetään pois sellaiset muuttujat, joiden korrelaatiot mallin muiden mahdollisten muuttujien kanssa ovat Evansin (1996, Beldjatzia & Alatou 2016 ja Mikó ym. 2014 mukaan) luokittelussa erittäin heikot (korrelaatio 0-0,19). Nähdään, että *lcost*, *cur29*, *trcontr* sekä julkisten menojen muuttujien differenssit näyttäisivät korreloivan muiden muuttujien kanssa heikosti.

Liitteessä 5 tutkitaan differenssin korrelaatioiden pitkäaikaista kehittymistä. Tarkastellaan seuraavaksi BKT:n tai korjatun BKT:n differenssin ja muiden stationarisoitujen muuttujien viiveiden korrelaatioita sekä korrelaatioiden kehittymistä. Huomataan, että korrelaatioiden suuruudet ja jopa suunnat saattavat muuttua tarkasteluajanjaksolla. Esimerkiksi vientikorin ja kulutuksen differenssien korrelaatiot BKT-muuttujien differenssien kanssa muuttuvat voimakkaasti. Joidenkin muuttujien differenssin korrelaatiot BKT:n tai korjatun BKT:n differenssin kanssa ovat koko ajanjaksolla tarkasteltuna merkittäviä, mutta korrelaatiossa tapahtuu ajan myötä merkittäviä muutoksia. Arvioidaan, että ne antavat keskimäärin heikompi ennustuksia kuin korrelaatioltaan vakaina pysyvät muuttujat.

## 4. VAR-MALLIEN VALINTAKRITEERIT

Tämä luku kattaa VAR-mallien hyvyydelle asetetut periaatteet ja sen, millä perusteella yhtä ennustemallia voidaan pitää toista parempana. Luvut 4 ja 5 muodostavat kokonaisuuden VAR-mallien rakentamisessa: luku 4 esittelee valintakriteerit ja niiden käytön, luku 5 vastaavasti valintakriteereillä saadut tulokset.

Valintakriteerit jaotellaan kolmeen tyyppiin. Ensimmäinen sopivaa ennustemallia valitessa on keskeistä, että malli ennustaa keskimäärin mahdollisimman tarkasti. VAR-mallin muuttujavalintaa, funktiomuotoa ja muuta mallin spesifikaatiota valittaessa mallin hyvyyden kriteerinä käytetään perinteisesti ennusteen tarkkuutta (Robertson & Tallman 1999). Alaluvussa 4.1 tarkastellaan ennusteiden tarkkuuteen perustuvia kriteereitä: mallien ennusteiden RMSE-tunnuslukujen suuruutta, mallien ennustamien vuosikasvuasteiden poikkeamaa toteutuneesta vuosikasvuasteesta sekä mallien ennustetarkkuutta ARIMA:an verrattuna. Mallien ennustetarkkuuden vertailussa painotetaan erityisesti BKT-muuttujan ennustetarkkuuden vertailua eri mallien välillä.

Toiseksi on tärkeää varmistaa ennustemallin luotettavuus siten, että hyvän ennustetarkkuuden lisäksi rakennettu VAR-malli on sopusoinnussa talousteorian kanssa. Tämän vuoksi alaluvussa 4.2 tutkitaan mallien impulssivasteita ja alaluvussa 4.3. Grangerin kausaalisuustestin periaatteita ja merkitystä mallien hyvyyden määrittämisessä.

Kolmanneksi ennusteen laatijan ja käyttäjän on keskeistä tietää, kuinka suuri vaikutus muuttujien mittausvirheillä on ennusteisiin. Ennustemallin hyvä vastustuskyky aineiston viimeisten havaintojen epätarkkuuksille lisää ennusteiden varmuutta. Herkkyysanalyysillä voidaan selvittää mallin ennusteiden herkkyys eri muuttujien mittausvirheille. Herkkyysanalyysin ensisijaisena tarkoituksena on antaa tietoa estimoiduista malleista, mutta siitä saatua tietoa voi joissain tapauksissa hyödyntää myös mallin valinnan perusteena. Herkkyysanalyysiä käsitellään alaluvussa 4.4.

### 4.1. Ennusteiden tarkkuuteen perustuva mallin valinta

Mallin ennusteiden tarkkuus on yksi keskeisimmistä mallin hyvyyden kriteereistä. Ennustetarkkuuden hyödyntäminen mallin valinnassa on keskeistä, sillä esimerkiksi t-testisuureen tai  $R^2$ -testisuureen käyttäminen mallin valinnan perusteena voi osoittautua tarkoituksen vastaiseksi

(Mayer 1975). Mallin korkea selitysaste on mahdollista saavuttaa valikoimalla mallin muuttujat tarkoituksenmukaisesti selittämään havaintoja estimointiperiodin sisällä. Tällä tavoin rakennettu malli ei yleensä pysty selittämään tai ennustamaan estimointiperiodin ulkopuolisia havaintoja, jolloin sen hyvyys myös estimointiperiodin sisällä on kyseenalaista (Mayer 1975). Mallien informaatiokriteereitä ja parametriestimaattien t-testisuureita on siksi seurattu vain pintapuolisesti. Ennustetarkkuuden perusteella valituissa malleissa esiintyy välillä muuttujia, jotka eivät ole t-testisuureen perusteella tilastollisesti merkitseviä, mutta joita käyttämällä keskimääräinen ennustetarkkuus on kasvanut. Tällainen muuttuja on esimerkiksi työvoimakustannukset työntekijää kohti Suomessa (*lcost*).

Ennustetarkkuuden määrittelyssä voidaan käyttää ennusteiden keskineliövirhettä MSE (mean squared error) (Lütkepohl 2005, 33), keskineliövirheen neliöjuurta RMSE (root mean squared error) tai ennusteen keskipoikkeamaa MAE (mean absolute error) (Robertson & Tallman 1999). Esimerkiksi Allen ja Fildes (2001) vertailevat kirjallisuuskatsauksessaan ennustemalleja niiden RMSE-tunnuslukujen perusteella. Vaihtoehtoisesti mallin valinnassa voidaan käyttää jotain muuta ennustetarkkuutta mittaavaa tunnuslukua (Robertson & Tallman 1999). Tässä tutkimuksessa mallin hyvyden kriteerinä on ollut ennustetarkkuus RMSE-kriteereillä tai vuosikasvuasteen virheillä mitattuna. Alaluvut 4.1.1. ja 4.1.2. esittelevät näiden hyvyyskriteerien käytön.

Todellisessa ennustetilanteessa ennustettavan ajanjakson havainnot eivät ole tiedossa, vaan malli estimoidaan ilman ennusteajanjakson havaintoja. Ennusteajanjakso sijoittuu siis estimointiajanjakson ulkopuolelle. Estimointiotoksen ulkopuolella tehtävää ennustetta kutsutaan out-of-sample-ennusteeksi. Kattakoon koko aineisto aikavälin  $[T_0, T]$ . Out-of-sample-ennusteissa estimointiotos sijoittuu periodille  $[T_0, T-h]$ , ja ennustejakso periodille  $[T-h+1, T]$ . Esimerkiksi kevään ennustetilanteessa estimointiotos päättyy vuoden viimeisen neljännesvuoden havaintoon, ja ennusteajanjakso alkaa seuraavan vuoden ensimmäisestä neljännesvuodesta.

VAR-malleilla ennustetaan samanaikaisesti useita peräkkäisiä neljännesvuosia. Useita periodeja sisältävissä ennusteissa ennustetaan dynaamisesti. Dynaamisessa ennustuksessa periodeittain etenevä vaiheittainen ennuste laskee seuraavan periodin arvon käyttämällä mallin muuttujille ennustamia arvoja niiden todellisten arvojen sijaan. Tämä mahdollistaa usean periodin mittaisen ennustamisen, koska edellisen periodin ennustetuloksen realisoitumista ei tarvitse odottaa. Dynaaminen ratkaisu on erotuksena staattiseen ratkaisuun, jossa edellisen periodin endogeenisten arvojen on realisoituttava ennen, kuin uuden periodin arvot voidaan ratkaista. Dynaaminen ratkaisu

vastaa todellista ennustetilannetta, jossa ennuste tehdään useita periodeja eteenpäin.

Ennusteiden tarkkuus selvitetään siten, että kullekin mallille tehdään dynaaminen out-of-sample-ennuste heti estimointijakson päättymistä seuraavasta periodista alkaen seuraaville kuudelle tai kahdeksalle vuosineljännekselle. Ennusteessa hyödynnetään mallin estimoituja parametreja sekä viiveen pituuden  $p$  mukaisesti aineiston  $p$  viimeisintä havaintoa. Tuloksena saadaan kunkin endogeenisen muuttujan ennustetut arvot neljännesvuosittain koko ennusteajanjaksolle.

VAR-mallien muuttujien valinnassa käytetään talousteoriaa ja liitteiden 4 ja 5 korrelaatiotaulukoita. Mallien keskinäisen paremmuusjärjestyksen määrittämiseksi käytetään kahta erilaista ennusteiden tarkkuuteen perustuvaa vertailualgoritmia. Tämän lisäksi malleja verrataan ARIMA:n antamiin ennusteisiin. Seuraavaksi alaluvuissa 4.1.1.–4.1.3. esitellään vertailualgoritmien sekä ARIMA:n käyttöä ennustevertailussa.

#### **4.1.1. RMSE-vertailualgoritmi**

RMSE-vertailualgoritmilla vertaillaan suurta määrää malleja samanaikaisesti ja valitaan ennustetarkkuudeltaan parhaiten menestyvät mallit. Luvuissa 5.1.1.-5.1.3. esitellään mallit, joihin vertailualgoritmia on käytetty. Vertailualgoritmin välivaiheet etenevät seuraavasti:

1. Valituille muuttujille estimoidaan VAR-malli alkaen vuodesta 1990 päättyen hetkeen  $T-h$ , joka on viimeinen periodi ennen ennusteajanjakson alkua. Estimoinnissa käytetään stationaaristen muuttujien aikasarjoja sellaisenaan, kun taas epästationaarisisista aikasarjoista otetaan logaritmin differenssi ennen estimointia.
2. Estimoidulle mallille tehdään out-of-sample-ennuste, jonka kesto on syksyn ennustetilannetta mallintavissa ennusteissa kuusi vuosineljännestä ja kevään ennustetilannetta mallintavissa ennusteissa kahdeksan vuosineljännestä. Ennuste alkaa tällöin periodista  $T-h+1$  ja päättyy kevään ennusteissa periodiin  $T-h+8$  ja syksyn ennusteissa periodiin  $T-h+6$ .
3. Ennuste osoittaa VAR-mallin kullekin muuttujalle ennustetun kasvuasteen vuosineljänneksittäin. Verrataan BKT:n tai korjatun BKT:n muuttujan ennustetta toteutuneisiin BKT:n tai korjatun BKT:n arvoihin laskemalla koko ennustejakson keskineliövirheen neliöjuuri (RMSE):



$$\sqrt{\sum_{i=T-h+1}^T \frac{(\hat{y}_t - y_t)^2}{h}} \quad \text{missä}$$

$\hat{y}_t$  = muuttujan ennustettu arvo hetkellä t

$y_t$  = muuttujan toteutunut arvo hetkellä t ja

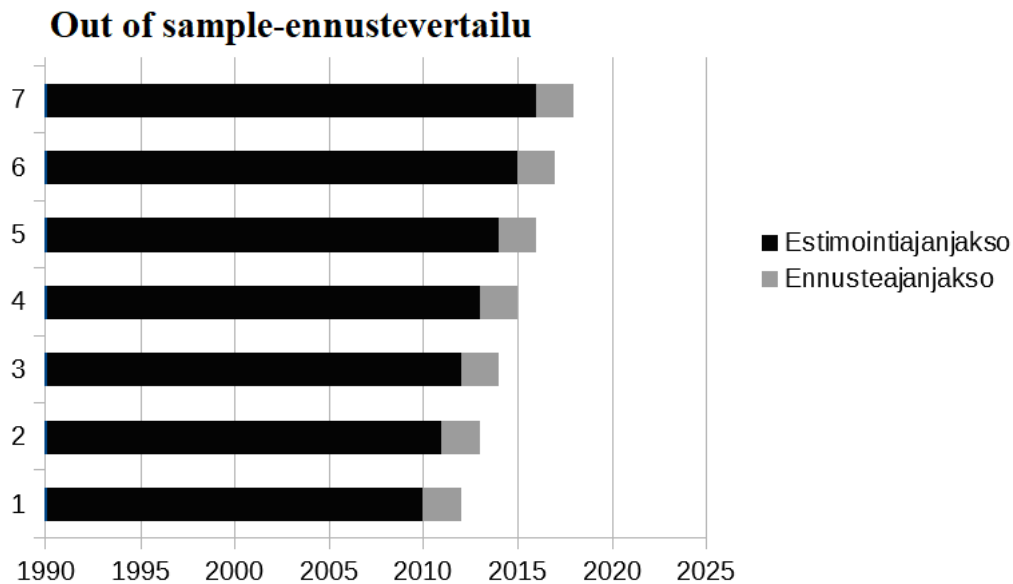
h =ennusteajanjakson pituus.

RMSE:lle on ominaista rangaista suuresta ennustevirheestä suhteellisesti enemmän kuin pienestä ennustevirheestä. Vaihtoehtoinen tapa järjestää ennusteet paremmuusjärjestykseen on keskipoikkeama (mean absolute error, MAE):

$$\sum_{i=T-h+1}^T \frac{|y_t - \hat{y}_t|}{h} .$$

Keskipoikkeama on helpommin ymmärrettävissä kuin keskineliövirheen neliöjuuri, mutta se rankaisee suuresta ennustevirheestä samassa suhteessa kuin pienestä ennustevirheestä. Tässä tutkimuksessa tehdyissä ennustevertailuissa mallien sijoitusjärjestyksellä RMSE- ja MAE-kriteereillä mitattuna ei ollut suurta eroa.

4. Tallennetaan yksittäisen mallin yksittäiselle ajanjaksolle tehdyn ennusteen keskineliövirheen neliöjuuri.
5. Toistetaan edelliset vaiheet kaikille vertailtaville ennustemalleille.
6. Toistetaan edelliset vaiheet kaikille tarkasteltavissa oleville ennusteajanjaksoille. Ennustevertailuissa ennusteet suoritettiin vuosittain vuodesta 2010 alkaen päättyen vuoteen 2016. Tällöin vuoden alusta alkavia kahden vuoden mittaisia ennusteajanjaksoja kertyy yhteensä seitsemän (vrt. kaavioon 4.1.).
7. Summataan mallien kunakin vuonna saamat BKT:n tai korjatun BKT:n ennusteen RMSE:t ennusteajanjaksoilta jokaiselle mallille.
8. Asetetaan mallit järjestykseen RMSE-summan mukaan. Valitaan malleista ne, joiden ennusteiden RMSE oli keskimäärin pieni ja joiden RMSE oli vähintään yhtä pieni (tai korkeintaan niukasti suurempi) kuin ARIMA(1,1,2):lla tehdyn ennusteen RMSE samalla ennusteajanjaksolla. ARIMA:lla ennustamista esitellään luvussa 4.1.3. Ennustevertailun etenemistä havainnollistetaan kaaviossa 4.1.



*Kaavio 4.1: Out of sample -ennustevertailujen eteneminen kevään ennustetilannetta mallintavissa kahdeksan vuosineljänneksen (kahden vuoden) mittaisissa ennusteissa seitsemällä ennusteajanjaksolla aikavälillä 2010-2016.*

Kun RMSE-vertailualgoritmia on rakennettu, tavoitteena on ollut laatia sellainen kriteeri, joka suosii hyvin ennustavia ja vähän riskiä sisältäviä malleja. Toisin sanoen kriteerin mukaan joka vuosi tasaisen hyvin ennustava malli on parempi kuin sellainen, joka useimpina vuosina ennustaa hyvin tarkasti, mutta erehtyy silloin tällöin hyvin raskaasti. VAR-malli on pudotettu pois, jos ennustevertailussa on ollut yksikään ennusteajanjakso, jolla VAR-mallin antama ennuste on ollut RMSE-kriteerillä mitattuna merkittävästi heikompi kuin saman ennusteajanjakson ARIMA-mallin antama ennuste. Tästä johtuen ennustevertailussa on saattanut pudota pois sellaisia malleja, joiden ennuste on keskimäärin tarkka, mutta jotka ovat ennustaneet seitsemästä kahden vuoden ennusteajanjaksosta vähintään yhden selvästi heikommin kuin ARIMA. On mahdollista, että osalla pudotetuista malleista ennustetarkkuus olisi heikkojen ennusteiden vuosina parantunut muuttamalla mallin funktiomuotoa tai jotain muuta mallin spesifikaatiota. Tällöin olisi ollut perusteltua käyttää mallin valinnan kriteerinä ainoastaan mallien ennusteiden RMSE-summia ja verrata, kuinka tarkka VAR-mallin ennuste on keskimäärin ARIMAan verrattuna.

#### **4.1.2. Vuosikasvuasteeseen perustuva vertailualgoritmi**

Kun RMSE-vertailualgoritmi on karsinut suurimman osan malleista, on jäljelle jääviä malleja vertailtu vuosikasvuasteeseen perustuvalla vertailualgoritmillä. RMSE-vertailualgoritmissa

käytettävä neljännesvuosiennusteiden RMSE-tunnuslukujen vertailu on paljon käytetty tapa arvottaa eri mallien hyvyttä, mutta RMSE:t eivät ole kovinkaan havainnollisia tunnuslukuja käytännön ennustetyössä. Palkansaajien tutkimuslaitoksen ennustetyössä olennaista on, kuinka tarkasti mallin voidaan olettaa ennustavan muuttujien vuosikasvuasteet. Ennustejulkaisuissa talouden kehitystä kuvataan vuositasolla neljännesvuositason sijaan. Vuosikasvuasteeseen perustuva vertailualgoritmi on rakennettu palvelemaan tätä tarkoitusta. Algoritmista neljännesvuosiennusteet on aggregoitu vuosille, ja vuosikasvuasteen ennusteita on verrattu toteutuneeseen vuosikasvuasteeseen. Alaluvussa 5.1.4 kuvataan suppeasti, millaisia malleja vuosikasvuasteeseen perustuvalla vertailualgoritmilla on viety läpi. Työpaperissa (Korhonen 2018) esitellään vertailualgoritmissa vertailut mallit yksityiskohtaisesti. Vuosikasvuasteeseen perustuva vertailualgoritmi on toteutettu seuraavasti:

1. Suoritetaan RMSE-vertailualgoritmin vaiheet 1 ja 2.
2. RMSE-keskivirheiden laskemisen sijaan neljännesvuosiennusteet summataan vuosille ja muuttujien vuosittaiset kasvuasteiden ennusteet tallennetaan. Sekä kuuden että kahdeksan neljännesvuoden ennusteissa ennusteajanjakso ulottuu kahdelle vuodelle, joten neljännesvuosiennusteiden summaamisen seurauksena mallin kullekin muuttujalle saadaan kaksi vuosittaista kasvuaste-ennustetta.
3. Vähennetään mallin muuttujalle ennustamasta vuosittaisesta kasvuasteesta muuttujan toteutunut kasvuaste. Prosenttiyksiköissä ilmaistuista ennusteista ja toteutuneista arvoista tehty erotus on edelleen prosenttiyksiköissä. Kutsutaan saatua erotusta ennustevirheeksi. Korotetaan mallin ennustevirhe toiseen potenssiin. Valintakriteerinä käytetään ennustevirheen neliösummaa, mutta ennustevirheiden itseisarvon keskiarvolla voidaan havainnollistaa ennustevirheiden suuruutta.
4. Suoritetaan RMSE-vertailualgoritmin vaiheet 5 ja 6.
5. Summataan ennustevirheiden neliöt kullekin mallille ja asetetaan mallit paremmuusjärjestykseen ennustevirheen neliösumman perusteella.

VAR-mallien ja ARIMA-mallin muuttujaennusteen kunkin vuoden kasvuaste-ennusteista vähennetään toteutunut kasvuaste. Liian optimistinen kasvuennuste johtaa positiiviseen ennustevirheeseen ja liian pessimistisen kasvuennuste johtaa negatiiviseen ennustevirheeseen. Neliöittäessä kaikki tunnusluvut ovat positiivisia, ja suurta kasvuasteessa tapahtunutta ennustevirhettä rangaistaan suhteellisesti enemmän kuin pientä kasvuasteessa tapahtunutta virhettä.

BKT:n ja korjatun BKT:n muuttujien VAR- ja ARIMA-mallien ennustevirheiden neliöitä vertaillaan keskenään. Sen sijaan VAR-mallien muilla muuttujilla ennustetarkkuuden mahdollista heikkoutta suhteessa ARIMA-mallin ennustetarkkuuteen ei pidetä mallia eliminoivana tekijänä. Prosenttiyksiköissä ilmaistut neliöidyt ennustevirheet on kullakin mallilla summattu ennusteajanjaksoilta ja malleja on täten vertailtu keskenään kaikki ennusteajanjaksot kattavalta ajalta.

Neljännesvuosiennusteet pohjautuvat neljännesvuosiaineistoon. Niitä koskevat vuodet on aggregoitu. Aggregointi ja siitä tehtävä vertailu on perusteltua Allenin ja Fildesin (2001) artikkelin nojalla. Vaikka aggregoinnissa menetetään runsaasti potentiaalisesti merkittävää tietoa (Rossana & Seater 1995), ennusteen tehokkuus kärsii vähemmän, kun aggregointi vuosille tehdään ennustamisen jälkeen eikä ennen ennustamista (Judge ym. 1985, 406, 674 –675). Tämän lisäksi alkuperäinen viivekuvio voi aggregoinnin seurauksena poistua tai muuttua, jos kausitasoittamattomalle aineistolle on tehty aggregointi ennen ennustamista (Allen & Fildes 2001). Koska kerätty aineisto on kausitasoitettu, siinä ei esiinny kausivaihtelua.

#### ***4.1.3 Vertailu ARIMA:an***

Ennusteiden tarkkuuteen perustuvassa mallien valinnassa mallien ennustetarkkuutta on vertailtu paitsi toisiinsa, myös ARIMA:an. Vertailua perustellaan sillä, että VAR-mallien estimointi ja käyttäminen ennustetyössä on kannattavaa vain, jos VAR-malli pystyy ennustamaan paremmin kuin puhtaasti todennäköisyyksiin perustuva, taloustieteellistä näkemystä vaille oleva malli. Toisin sanoen, jos yksinkertaiseksi katsotulla ARIMA-mallilla on mahdollista ennustaa talouden muuttujia vähintään yhtä hyvin kuin jollakin tutkimuksessa estimoidulla VAR-mallilla, VAR-malli on laadultaan heikko eikä sovi ennustetarkoitukseen.

ARIMA-mallit ovat nimensä (autoregressive integrated moving average) mukaisesti stationaariseen tai epästationaariseen aikasarjaan perustuvia malleja, joiden estimointi perustuu aikasarjan autoregressiiviseen prosessiin ja muuttuvan keskiarvon prosessiin. Toisin sanoen ARIMA-malleissa muuttujan tulevia arvoja ennustetaan vain muuttujan menneillä arvoilla käyttämättä muiden muuttujien aikasarjoja. ARIMA siis tarjoaa VAR-malleille yksinkertaisen vaihtoehdon taloustieteellisten muuttujien ennustamiseen. ARIMA (p,d,q) voidaan esittää muodossa

$$\begin{aligned}\phi(B)\bar{V}^d y_t &= \theta(B)a_t \\ \phi(B) &= 1 - \phi_1 B - \dots - \phi_p B^p \\ \theta(B) &= 1 - \theta_1 B - \dots - \theta_q B^q\end{aligned}$$

missä

p = autoregressiivisen AR-prosessin kertaluku

d = differenssien määrä

q = moving average MA-prosessin kertaluku

$\phi_1, \dots, \phi_p$  ja  $\theta_1, \dots, \theta_q$  ovat parametristimaatteja.

$a_t$  on riippumattomien virhetermien ketju, jossa virhetermin varianssi on  $\sigma^2$

B on siirto-operaattori taaksepäin  $By_t = y_{t-1}$

$\bar{V}^d y_t = (1-B)^d y_t$  on aikasarjan y d:s differenssi. (Box & Pierce, 1970.)

VAR-mallissa esiintyviä muuttujia ennustettiin useilla erilaisilla ARIMA-malleilla aikavälillä 2010-2016. Kullekin muuttujalle estimoitiin omia ARIMA-malleja, joille tehtiin out-of-sample-ennusteita alaluvussa 4.1.1. kuvattuun tapaan. Kunakin ennusteajanjaksona kunkin muuttujan ARIMA-malleista poimittiin lähimmäksi oikeita muuttujan arvoja ennustanut ARIMA-malli. Lopulta kunkin muuttujan ARIMA-malliksi valittiin useimpina ennusteajanjaksoina parhaiten ennustanut ARIMA-malli. MSE-kriteerein estimoitu ARIMA (1,1,2) ennusti useampina ennusteajanjaksoina tarkemmin kuin yksikään muu ARIMA-malli. Tulos päti kaikkiin VAR-mallin muuttujiin.

Ennustevertailuissa hyödynnettävä ARIMA (1,1,2) on nyt muotoa

$$\begin{aligned}Y_t - Y_{t-1} &= \phi_1(Y_{t-1} - Y_{t-2}) - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} + \varepsilon_t \\ Y_t &= Y_{t-1} + \phi_1(Y_{t-1} - Y_{t-2}) - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} + \varepsilon_t\end{aligned}$$

## 4.2. Impulssivasteet

Edellä on esitelty periaatteita, joihin nojautuen mallin hyvyttä voidaan selvittää ennustetarkkuuteen perustuvien kriteerien avulla. Ennustemallin toinen luotettavuuden kriteeri ennustetarkkuuden ohella on, että se on sopusoinnussa makrotaloustieteellisen teorian kanssa. Tämä ja seuraava keskittyvät ennustemallin estimoinnin talousteorianäkökulmaan.

Kaikki empiiriset mallit sisältävät rajallisen määrän muuttujia, eivätkä ne siten tallenna

kaikkea mallin muuttujiin vaikuttavaa tietoa. Yksikään tässä tutkimuksessa estimoitu VAR-malli ei siis pysty selittämään kaikkia sen muuttujissa tapahtuvia muutoksia, vaan osa muutoksista näyttäytyy mallissa häiriötekijöinä eli shokkeina. Shokit heijastelevat sellaisia vaikutuksia, joissa VAR-mallin ulkopuolella oleva muuttuja vaikuttaa johonkin tai joihinkin VAR-mallin sisällä oleviin muuttujiin. Impulssivasteiden avulla voidaan selvittää, miten mallin muuttujat reagoivat yhdessä mallin muuttujassa tapahtuvaan kertaluontoiseen shokkiin eli impulssiin.

Ennustemallin kannalta on keskeistä, ovatko impulssin aiheuttamat vasteet mallin muuttujissa suunnaltaan talousteorian kanssa yhteensopivia. Yleissääntönä voidaan pitää, että malli, jonka impulssivasteet noudattavat makrotaloustieteessä yleisesti tunnettuja relaatioita, on parempi kuin malli, jonka impulssivasteet näyttäisivät toimivan talousteorian vastaisesti. Sopivien ennustemallien valinta on suoritettava tätä sääntöä mukaillen.

On mahdollista, että ennusteiden tarkkuudessa poikkeuksellisen hyvin menestyvän mallin impulssivasteet osoittautuvat talousteorian vastaisiksi. Saattaa esimerkiksi selvitä, että mallin yhtälöillä investointien positiivinen shokki eli mallin ulkopuolelta aiheutunut kasvu laskee bruttokansantuotetta tai että työttömyyden positiivinen shokki kasvattaa bruttokansantuotetta. Tällaisissa tilanteissa voidaan epäillä, että mallista puuttuu joitain keskeisiä muuttujia eikä rakennettu malli hyvästä ennustekyvystään huolimatta pysty mallintamaan todellista tiedon generointiprosessia. Virheellisen mallintamisen seurauksena mallin hyvä ennustekyky tulevilla ennusteajanjaksoilla voi olla kyseenalainen. Tässä tutkimuksessa rakennetuilta ennustemalleilta vaaditaan impulssivasteiden yhteensopivuutta talousteorian kanssa.

Tarkastellaan impulssivasteita esimerkin avulla. Olkoon tarkasteltavana kolmen muuttujan stationaarinen VAR(1)-malli  $Y_t = A + BY_{t-1} + U_t$

$$\begin{bmatrix} y_{1,t} \\ y_{2,t} \\ y_{3,t} \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \\ a_{30} \end{bmatrix} + \begin{bmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \\ b_{31} & b_{32} & b_{33} \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \\ y_{3,t-1} \end{bmatrix} + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \end{bmatrix} .$$

Näillä oletuksilla aikasarjan muuttujat lähestyvät pitkällä aikavälillä matriisin A arvoja, eli  $(y_1, y_2, y_3) \rightarrow (a_{10}, a_{20}, a_{30})$ . Käytetään esimerkkinä BKT:n, Euroopan unionin BKT:n sekä investointien suhdetta käsittelevä mallia ( $y_1 = \text{dlogbkt}$ ;  $y_2 = \text{dlogbkt28}$ ;  $y_3 = \text{dlogi}$ ). Kun muuttujana on suureen logaritmin differenssi, kunkin muuttujan keskiarvo on tasapainouran kasvuaste. Olkoon mallin kerroinmatriisien A ja B estimaatit

$$\begin{bmatrix} a_{10} \\ a_{20} \\ a_{30} \end{bmatrix} = \begin{bmatrix} 0,02 \\ 0,02 \\ 0,02 \end{bmatrix}$$

$$\begin{bmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \\ b_{31} & b_{32} & b_{33} \end{bmatrix} = \begin{bmatrix} 0,2 & 0,1 & 0,1 \\ 0 & 0,4 & 0 \\ 0,2 & 0 & 0,3 \end{bmatrix} .$$

VAR-malli on stationaarinen, jos kerroinmatriisin B ominaisarvot  $z_1, z_2, \dots, z_n$  ovat itseisarvoltaan pienempiä kuin 1. Ominaisarvot voidaan ratkaista lausekkeen  $\det(zI - A)$  nollakohdista:

$$\left| \begin{bmatrix} z & 0 & 0 \\ 0 & z & 0 \\ 0 & 0 & z \end{bmatrix} - \begin{bmatrix} 0,2 & 0,1 & 0,1 \\ 0 & 0,4 & 0 \\ 0,2 & 0 & 0,3 \end{bmatrix} \right| = \begin{vmatrix} z-0,2 & -0,1 & -0,1 \\ 0 & z-0,4 & 0 \\ -0,2 & 0 & z-0,3 \end{vmatrix} = 0 .$$

(Lütkepohl 2005, 652–653.)

Lauseke voidaan sieventää muotoon:

$$z^3 - 0,9z^2 + 0,24z - 0,016 = 0 .$$

$$(z_1, z_2, z_3) = (0,1; 0,4; 0,4)$$

VAR-malli osoittautuu stationaariseksi, koska kaikki juuret  $z_1, z_2, z_3$  ovat itseisarvoltaan pienempiä kuin 1.

Oletetaan, että periodilla  $t = 0$  muuttujassa  $y_1$  ( $dlogbkt$ ) tapahtuu kertaluonteinen yhden yksikön suuruinen shokki. Olettaen, että seuraavilla periodeilla virhetermit  $u$  ovat nollia, muuttujan  $y_1$  ( $dlogbkt$ ) yhden yksikön suuruudesta shokista seuraavat muuttujien arvot periodeilla  $t = 0, \dots, 3$  ovat

$$Y_0 = e = \begin{bmatrix} y_{1,0} \\ y_{2,0} \\ y_{3,0} \end{bmatrix} = \begin{bmatrix} u_{1,0} \\ u_{2,0} \\ u_{3,0} \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$$

$$Y_1 = \begin{bmatrix} y_{1,1} \\ y_{2,1} \\ y_{3,1} \end{bmatrix} = A + B y_0 = \begin{bmatrix} 1,02 \\ 0,02 \\ 0,02 \end{bmatrix}$$

$$Y_2 = \begin{bmatrix} y_{1,2} \\ y_{2,2} \\ y_{3,2} \end{bmatrix} = A + B y_1 = A + B(A + B y_0) = \begin{bmatrix} 0,228 \\ 0,1 \\ 0,23 \end{bmatrix}$$

$$Y_3 = \begin{bmatrix} y_{1,2} \\ y_{2,2} \\ y_{3,2} \end{bmatrix} = A + B y_2 = A + B(A + B(A + B y_0)) = \begin{bmatrix} 0,0986 \\ 0,06 \\ 0,1346 \end{bmatrix}$$

Periodilla  $t$   $Y$  on muotoa:

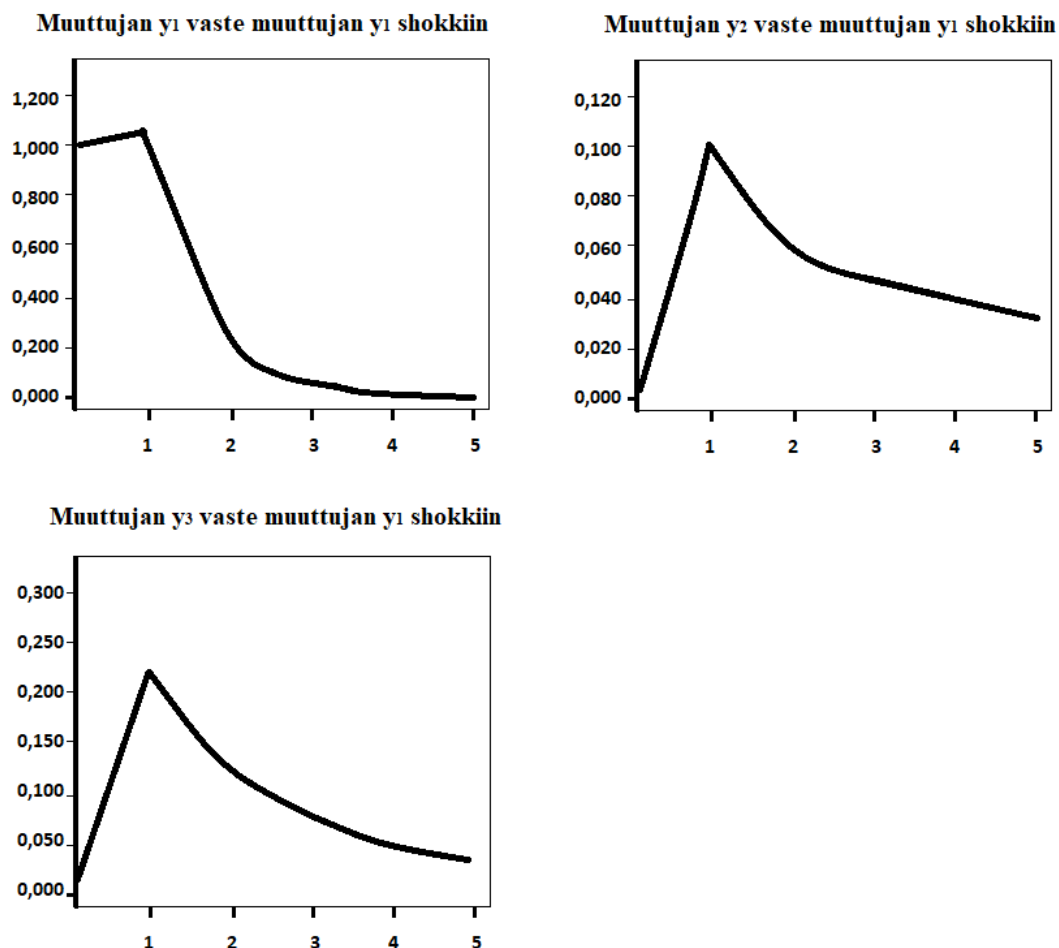
$$Y_t = A(1 + B + B^2 + B^3 + \dots + B^{t-1}) + B^t e$$

$$\lim_{t \rightarrow \infty} Y_t = (1 - B)^{-1} A + B^t e$$

$$\lim_{t \rightarrow \infty} Y_t = (1 - B)^{-1} A$$

Shokin vaikutus VAR-mallin muuttujien tuleviin arvoihin voidaan ilmaista myös graafisesti.

Kaaviossa 4.2. on kuvattu muuttujan  $Y$  impulssivasteet  $\frac{\partial y_{t+s}}{\partial e_t}$ .



Kaavio 4.2. Muuttujan  $y_1$  impulssin vasteet mallin kaikkiin endogeenisiin muuttujiin.



Muuttujan  $y_1$  impulssia tarkastelevasta esimerkistä käy ilmi, kuinka mallissa näkyy stationaarille VAR-mallille tyypillinen sarjan virhetermin vaikutuksen vaimeneminen; pitkällä aikavälillä aikasarja konvergoituu, eivätkä aiemmat virhetermit vaikuta muuttujien arvoihin ikuisesti. Lisäksi kaavio havainnollistaa yhden muuttujan shokin vaikutusta kaikkiin VAR-mallissa oleviin muuttujiin. On tapauksia, joissa yhden muuttujan  $y_i$  impulssit eivät vaikuta lainkaan mallin muihin muuttujiin. Näin käy silloin, kun muuttuja  $y_i$  ei Granger-kausalisuuden mielessä saa aikaan VAR-mallin yhdenkään toisen muuttujan arvoja. Tällöin ainoastaan innovaatiomuuttujan oma impulssivaste poikkeaa nolasta (Lütkepohl 2005, 54).

Impulssivastefunktiot ovat symmetrisiä siten, että positiivisen ja negatiivisen shokin generoimat impulssivasteet ovat itseisarvoltaan yhtä suuret (Lin 1997). Ekonometrisilla ohjelmilla voidaan laskea ja piirtää kuviot vasteista, jotka kunkin VAR-mallin muuttujan impulssit aiheuttavat muihin muuttujiin shokkiperiaodia seuraavina periodeina.

Jos mallin muuttujilla on eri skaala, impulssivasteet on tapana tehdä yhden hajonnan suuruisille shokeille yhden yksikön suuruisten shokkien sijaan. Tässä aineistossa esimerkiksi investointien aikasarja on hyvin volatiili, kun taas *fi\_eu15* näyttäytyy varsin vakaana. Kunkin muuttujan keskimääräisen shokin suuruus riippuu muuttujan hajonnasta, jolloin impulssien asettaminen muuttujien hajontojen suuruiseksi havainnollistaa muuttujien välisiä suhteita paremmin kuin niiden pitäimen yhden yksikön suuruisina. (Lütkepohl 2005, 53.) Tässä tutkimuksessa impulssivasteet suoritetaan siis muuttujan yhden hajonnan suuruisille shokeille.

Jos VAR-mallin muuttujien shokit eivät ole toisistaan riippumattomia, on mielekästä tarkastella usean muuttujan yhtäaikaista shokkia. Virhetermien keskinäinen korrelaatio voi syntyä siitä, että mallin ulkopuolelle on jäänyt mallin kaikkiin muuttujiin vaikuttava muuttuja. (Lütkepohl 2005, 57.) Tässä tutkimuksessa tarkastelua on yksinkertaistettu, ja impulssivasteita katsotaan vain yhden muuttujan shokki kerrallaan.

Impulssivastetarkasteluun sisältyy joitain varauksia. Impulssivasteet, samoin kuin Grangerin kausalisuustesti, voivat antaa mallista epätäydellisen kuvan, jos käsiteltävä malli on spesifioitu virheellisesti. Näin voi käydä esimerkiksi silloin, kun mallista puuttuu tärkeitä muuttujia. Kaikkien mallista pois jääneiden muuttujien vaikutukset voivat näkyä vain virhetermeissä, sillä vaikutusten selittäjä on estimoidun mallin ulkopuolella. Jos mallista on jäänyt pois tärkeitä muuttujia, impulssivasteisiin voi syntyä häiriötä. Tällöin mallin rakenteen liittyvät tulkinnat ovat harhaisia, mutta malli voi tästäkin huolimatta toimia hyvänä ennustajana. (Lütkepohl 2005, 62.)

Vaikka impulssivasteet antavat tietoa shokkien aiheuttamien muutosten etumerkistä ja suuruudesta, muuttujien välisten kausaalisuhteiden päättely impulssivasteiden avulla on epätarkkaa. Tämän vuoksi mallien sisäisen dynamiikan tarkastelu vaatii impulssivasteiden selvittämisen lisäksi Granger-kausalisuhteiden määrittelemistä.

### 4.3 Grangerin kausaalisuustesti

Jatketaan mallien valintakriteerien asettamista siitä näkökulmasta, että estimoidun VAR-mallin on oltava talousteoreettisesti mielekäs. Tässä alaluvussa käsitellään kausaalisuuden määrittelyä VAR-mallien ympäristössä. Käytetyimmissä makrotaloudellisissa ennustemalleissa muuttujien väliset syy-seuraussuhteet ovat helposti tunnistettavissa mallin rakenteesta, koska mallien estimoinnissa muuttujat jaetaan endogeenisiin ja eksogeenisiin. VAR-malleja estimoidessa kaikki muuttujat asetetaan endogeenisiksi, jolloin mallin muuttujien välistä kausaalisuutta ei voida päätellä suoraan. Ekonomisti Clive Grangerin (1969) kausaalisuustesti on ekonometriassa yleisesti käytetty menetelmä muuttujien välisten syy-seuraussuhteiden selvittämiseen.

Grangerin testausperiaate perustuu olettamukseen, että syy ei voi syntyä seurauksen jälkeen (Granger 1969; Lütkepohl 2005, 41). Jos muuttuja  $y_2$  aiheuttaa muuttujan  $y_1$ , on oltava niin, että  $y_2$ :n menneiden arvojen käyttäminen parantaa  $y_1$ :n ennustetarkkuutta (Granger 1969; Lütkepohl & Krätzig 2004, 144). Grangerin kausaalisuuden käsite viittaa nimenomaan mallin muuttujan ennustetarkkuuden parantamiseen; tällöin ei ole merkitystä sillä, aiheuttaako muuttuja  $y_2$  tosiasiallisesti muuttujan  $y_1$ . Tarkastelusta sivuutetaan Granger-kausalisuuteen liittyvä välitön kausaalisuus, joka viittaa  $y_1$ :n ennusteen parantamiseen käyttämällä  $y_2$ :n saman periodin arvoja viivästettyjen arvojen sijaan (Granger 1969; Lütkepohl 2005, 48).

Ennustetarkkuuden määrittelyssä hyödynnetään variansseja. Kuvastakoon  $U_t$  kaikkea maailmassa saatavilla olevaa tietoa ajankohdasta  $t-1$  lähtien. Nyt  $y_{2t}$ :n komplementti  $U_t - y_{2t}$  käsittää kaiken tiedon pois lukien muuttujan  $y_{2t}$  aikasarjan. Nyt voidaan määritellä  $y_2$ :n aiheuttavan  $y_1$ :n, jos  $y_1$ :n ennuste on parempi käytettäessä kaikkea saatavilla olevaa tietoa kuin käytettäessä  $y_2$ :n komplementtia. Tämä voidaan ilmaista muodossa

$$\sigma^2(y_1|U) < \sigma^2(y_1|U - y_2) \quad . \text{ (Granger 1969.)}$$

$$\Leftrightarrow y_2 \Rightarrow y_1$$

Jos kausaalinen yhteys on molemminpuolinen, muuttujilla sanotaan olevan palautevaikutusta

(feedback effect):

$$\begin{aligned} \sigma^2(y_1|U) &< \sigma^2(y_1|U - y_2) \\ \sigma^2(y_2|U) &< \sigma^2(y_2|U - y_1) \\ &\Leftrightarrow \\ y_2 &\Leftrightarrow y_1 \end{aligned}$$

(Granger 1969, Lütkepohl 2005, 42.)

Grangerin kausaalisuustestissä yksinkertaistetaan tarkastelua rajoittamalla vain lineaarisiin ennustemenetelmiin (Granger 1969, Lütkepohl 2005, 43). Toinen keskeinen yksinkertaistus koskee muuttujaa  $U_t$ . Empiirisessä työssä ei ole käytännöllistä olettaa, että VAR-mallissa huomioitaisiin kaikki saatavilla oleva tieto  $U_t$ . Valtaosa kaikesta saatavilla olevasta tiedosta on ennusteen kannalta merkityksetöntä. Menetelmää voidaan yksinkertaistaa korvaamalla  $U_t$  estimoidun mallin aikasarjojen menneillä ja nykyisillä arvoilla. Kahden muuttujan esimerkissä  $U_t$  on nyt  $\{y_{1s}, y_{2s} \mid s \leq t\}$  (Lütkepohl 2005, 43). On huomattava, että jos mallista puuttuu tärkeitä muuttujia, syy-seuraussuhteista tehdyt päätelmät voivat olla virheellisiä. Jos kolmas muuttuja  $y_3$  aiheuttaa muuttujien  $y_1$  ja  $y_2$  arvot, niin  $y_{1:n}$  ja  $y_{2:n}$  välillä sanotaan olevan näennäiskausaalisuutta. (Granger 1969.)

Tarkastellaan Granger-kausalisuuden testaamista kolmen endogeenisen muuttujan VAR(p)-mallissa. Malli on muotoa

$$\begin{bmatrix} y_{1t} \\ y_{2t} \\ y_{3t} \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \\ a_{30} \end{bmatrix} + \sum_{i=1}^p \begin{bmatrix} b_{11,i} & b_{12,i} & b_{13,i} \\ b_{21,i} & b_{22,i} & b_{23,i} \\ b_{31,i} & b_{32,i} & b_{33,i} \end{bmatrix} \begin{bmatrix} y_{1,t-i} \\ y_{2,t-i} \\ y_{3,t-i} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \\ u_{3t} \end{bmatrix},$$

missä  $E(u_{1t}, u_{1s}) = E(u_{2t}, u_{2s}) = E(u_{3t}, u_{3s}) = 0$  kaikilla  $s \neq t$ . Muuttujan  $y_2$  voidaan todeta Granger-kausalisuuden näkökulmasta aiheuttavan  $y_{1:n}$  jos jokin  $b_{12,i}$  on nolasta poikkeava. Vastaavasti  $y_1$  aiheuttaa  $y_{2:n}$  jos jokin  $b_{21,i} \neq 0$ . (Granger 1969.) Vastaavasti stationaariseen ja vakaaseen VAR-prosessiin pätee, että  $y_2$  ei Granger-kausalisuuden näkökulmasta aiheuta  $y_{1:t}$ :tä, joss mallissa voidaan osoittaa että  $b_{12,i} = 0$  kaikilla  $i=1, \dots, p$ . (Lütkepohl 2005, 44–45 mukailleen.)


Grangerin kausalisuuden testaamiseen käytetään Waldin testiä, joka kertoo, poikkeako jokin VAR-mallin kerroinmatriisin alkio tilastollisesti nolasta. Yllä olevaa esimerkkiä jatkaen nollahypoteesina on, että  $y_2$  ei Granger-kausalisuuden mukaisesti aiheuta  $y_{1:t}$ :tä. Toisin sanoen:

$$H_0: b_{12,i} = 0 \text{ kaikilla } i = 1, \dots, p$$

$H_1: b_{12,i} \neq 0$  vähintään yhdellä  $i = 1, \dots, p$ . (Lütkepohl & Krätzig 2004, 148–149.)

Kun nollahypoteesi on tosi, Waldin testisuure noudattaa  $\chi^2$ -jakaumaa vapausasteella  $P$ , missä  $P$  on nollahypoteesin rajoitteiden määrä. Granger-kausaalisuutta testatessa rajoitteiden määrä vastaa mallin viiveiden määrää. (Lütkepohl & Krätzig 2004, 149.) Jos  $H_0$  jää voimaan, todetaan että  $y_2$  ei aiheuta  $y_1$ :tä Granger-kausaalisuuden mukaisesti. Jos  $H_0$  hylätään vaihtoehdoisen hypoteesin hyväksi, todetaan, että  $y_2$  aiheuttaa  $y_1$ :n (Lütkepohl 2005, 102-103).

Ennustemallia estimoidessa Grangerin kausaalisuustestiä hyödynnetään selvittäessä, kuinka tiiviisti VAR-mallin muuttujat kiinnittyvät toisiinsa Granger-kausaalisuuden näkökulmasta. Mallien valinnassa on tärkeää, että mallissa olevien kausaalisuhteiden verkko ulottuu kaikkiin muuttujiin. Toisin sanoen mallia valitessa sen muuttujien kausaalisuhteiden toivotaan linkittyvän toisiinsa siten, että niillä voidaan selittää VAR-mallille tyypillistä muuttujien välistä takaisinkytkentää. Kaavio 4.3. havainnollistaa Grangerin kausaalisuustestissä sovellettavaa mallin valintaa. Malleja valitessa niistä karsitaan pois kaikki sellaiset, joissa vähintään yksi muuttuja ei ole kausaalisessa suhteessa yhdenkään toisen mallin muuttujan kanssa (vertaa malliin B kaaviossa 4.3.). Ennustemalliksi ei myöskään kelpuuteta sellaista VAR-mallia, jossa kausaalisuhteet antaisivat olettaa, että mallin muuttujien keskinäinen vaikutus jakautuu muuttujaryhmässä osajoukkoihin (vertaa malliin C kaaviossa 4.3.). Tässä tutkimuksessa Grangerin kausaalisuustesteissä käytetään 95 prosentin luottamustasoa.



Kaavio 4.3. Mallivalinta Grangerin kausaalisuustestin perusteella. Mallin muuttujat on nimetty  $y_1$ - $y_4$ . Nuolet osoittavat Granger-kausaalisuuksien suunnan. Esimerkiksi mallissa A muuttuja  $y_4$  aiheuttaa Granger-kausaalisuuden näkökulmasta muuttujat  $y_2$  ja  $y_3$ . Molempiin suuntiin kulkeva nuoli tarkoittaa, että mallin muuttujilla on palautevaikutusta. Malli A vastaa VAR-mallin oletusta muuttujien välisestä takaisinkytkennästä. Mallissa B muuttujalla  $y_4$  ei ole Granger-kausaalisuuhdetta yhdenkään muuttujan kanssa. Mallissa C muuttujien Granger-kausaalisuhteet jakautuvat edelleen toisistaan irrallisiin osajoukkoihin.

#### 4.4 Herkkyysanalyysi

Mallin valintakriteerien viimeisessä osiossa käsitellään herkkyysanalyysiä, jossa tarkastellaan mallissa tapahtuvien muutosten ja virheiden vaikutusta mallista saataviin johtopäätöksiin (Pannell 1997). Ennustetyössä sekä kevään että syksyn ennusteet tehdään pian Tilastokeskuksen ja muiden virallisia tilastoja julkaisevien tahojen julkaistua kuluneen vuosineljänneksen tilastot. Julkaistut aikasarjat kuitenkin tarkentuvat vielä useita kuukausia niiden julkaisemisen jälkeen. Ennusteen tekijän ja ennusteen käyttäjän on tällöin keskeistä tietää, kuinka paljon aineiston tarkentuminen ja siten aikasarjan viimeisen tai viimeisten arvojen muuttuminen vaikuttaa muuttujien ennustettuihin kasvuasteisiin. Aikasarjan viimeisen arvon tarkentuminen voi vaikuttaa ennusteisiin merkittävästikin, mikäli estimoiduissa VAR-malleissa on lyhyet viiveet.

Tämän tutkimuksen herkkyysanalyysitarkastelussa selvitetään, kuinka paljon mallien ennusteet vääristyvät, kun jossakin mallin muuttujassa on mittausvirhe. Jos mallien muuttujien tarkentumiset ovat satunnaisia ja normaalisti jakautuneita, juuri ennen ennusteen tekoa julkaistuilla aikasarjoilla tehdyt ennusteet osuvat keskimäärin oikeaan. Tästä huolimatta herkkyysanalyysi tarjoaa ennusteen tekijälle ja käyttäjälle subjektiivisen luottamusvälin mallin muuttujien arvioiduista kasvuasteista. Jos mallien jonkin muuttujan arvo kuitenkin tarkentuu systemaattisesti ylös tai alas, tarjoaa herkkyysanalyysi merkittävää tietoa ennustetuista muuttujien kasvuasteista.

Herkkyysanalyysin peruseräteenä on muuttaa alkuperäistä mallia ja kirjata ylös sen tuloksissa tapahtuvat muutokset. VAR-mallien herkkyysanalyysissä tarkastellaan mallien aikasarjojen mittausvirheiden vaikutusta ennustetulokseen. Voidaan odottaa, että suuret mittausvirheet ja tarkennukset julkaistujen muuttujien aikasarjoissa aiheuttavat suuremman muutoksen kasvuaste-ennusteisiin kuin pienet mittausvirheet ja tarkennukset. Muuttujan arvon mittavien mittausvirheiden lisäksi mallit ovat herkkiä parametrien muutoksille silloin, kun mallista saatavat tulokset muuttuvat merkittävästi pienestäkin muutoksesta mallin parametreissa (Hamby 1994).

Matemaatikko Fiaccon (1983, 3) mukaan herkkyysanalyysin suorittaminen on osa tieteellisen tutkimuskysymyksen ratkaisua ja tämän ratkaisun ymmärtämistä. Herkkyysanalyysin avulla voidaan muun muassa selvittää, mitkä parametrit vaikuttavat malliin hyvin vähän ja voidaan siten poistaa mallista. Samalla voidaan määrittää muuttujat, joilla on eniten vaikutusta mallin tulosten vaihteluun. (Hamby 1994.) Lisäksi herkkyysanalyysi antaa tietoa siitä, kuinka suuria muutoksia mallin tuloksissa voidaan odottaa, jos jonkin mallin muuttujan parametrien arvot muuttuvat (Pannell

1997). Tällöin herkkyysanalyysissä selvitetään perusvaihtoehdon ja muiden vaihtoehtojen antamien tulosten erotus (Pannell 1997). Ennustetyön ympäristössä perusvaihtoehdolla tarkoitetaan alkuperäisellä aineistolla suoritettua ennustetta. Muilla vaihtoehdoilla tarkoitetaan tarkennetulla aineistolla suoritettua ennustetta silloin, kun aikasarjojen julkaisijoiden alkuperäisessä aineistossa on ollut mittausvirhe. Toisin sanoen muut vaihtoehdot kuvaavat, mitä muuttujien kasvuasteennusteet olisivat olleet, jos aikasarjojen todelliset arvot olisi tiedetty.

Tässä tutkimuksessa herkkyysanalyysitarkastelujen keskiössä on siis muuttujien aikasarjojen tarkentumisissa tapahtuva vaihtelu. Tästä syystä muuttujien omista aikasarjoista laskettuja vaihtelua kuvaavia kertoimia ei voida hyödyntää herkkyysanalyysilaskelmissa. Koska aikasarjojen tarkentumisen historia-aineisto on vaikeasti saatavilla, tässä tutkimuksessa käytetyt esimerkkiarvot tarkentumisten suuruudesta ovat vain suuntaa antavia.

Herkkyysanalyysissä voidaan hyödyntää lukuisia eri metodeja. Menetelmät voidaan jakaa lokaaleihin ja globaaleihin herkkyysanalyysihin. Lokaaleissa herkkyysanalyysissä tarkastellaan mallin herkkyyttä suhteessa parametriarvon piste-estimaatteihin, kun taas globaali herkkyysanalyysi selvittää mallin herkkyyden koko parametrin jakauman sisällä (Hamby 1995).

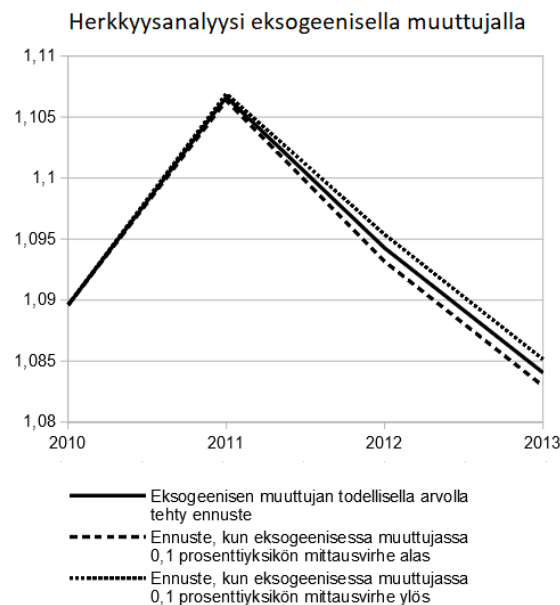
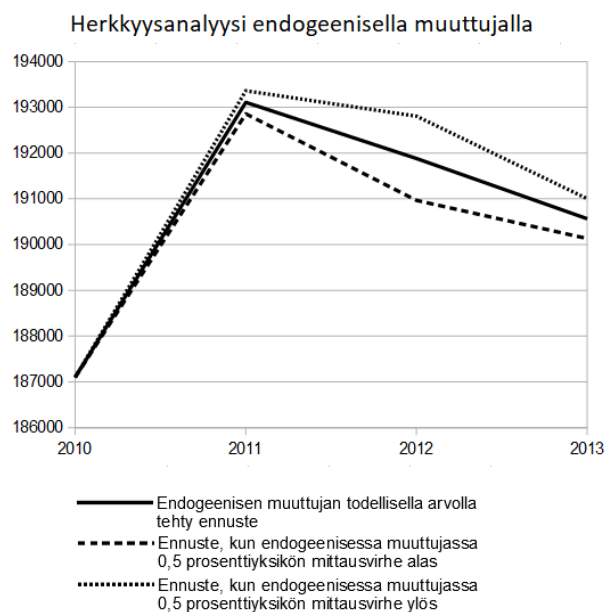
Herkkyysanalyysin metodeja ovat muun muassa differentiaaliherkkyysanalyysi (partial derivatives, PD), one-at-a-time-herkkyysanalyysi (OAT), herkkyysindeksi (sensitivity index, SI), tärkeysindeksi (importance index, II), suhteellisen hajonnan metodi (relative deviation method, RD), suhteellisen hajonnan suhdeluku (relative deviation ratio, RDR), korrelaatiokertoimiin perustuvat herkkyytunnusluvut sekä Smirnovin (S), Cramer-von Misesin (CM) ja Mann-Whitneyn (MW) testit (Hoffman ja Gardner 1983 Hambyn 1995 mukaan; Hamby 1994, 1995; Pannell 1997).

Valtaosassa herkkyysanalyysimenetelmissä on oletuksena, että mallin muuttujat ovat jaettavissa endogeenisiin ja eksogeenisiin ja todennäköisyysjakaumat ovat tunnettuja tai vähintään otoksen eri havaintojen voidaan olettaa olevan toisistaan riippumattomia. VAR-mallien ympäristössä nämä oletukset eivät ole realistisia. Tässä tutkimuksessa hyödynnetään lokaaleihin herkkyysanalyysimenetelmiin kuuluvaa one-at-a-time-herkkyysanalyysiä (OAT), jonka oletukset mallin spesifikaatiosta sopivat VAR-malleihin. Pannell (1997) lukee todennäköisyysjakaumat sivuuttavien lokaalien herkkyytarkastelujen eduksi sen, että helposti ymmärrettävän ja vähän perusteluja vaativan menetelmän tulokset on helppo ymmärtää ja uskoa. OAT-analyysissä mallin yhden muuttujan parametrin alkuperäistä arvoa vähennetään tai lisätään alkuperäisestä arvosta valitulla prosenttimäärällä tai hajontaluvulla. Tämän jälkeen lasketaan alkuperäisen arvon ja muutetun arvon

antamien tulosten erotus. (Hamby 1994, 1995.)

Tämän tutkimuksen one-at-a-time-herkkyysanalyysissä kunkin mallissa olevan muuttujan viimeisen viiveen arvoa muutetaan siten, että viimeisen vuosineljänneksen kasvuaste muuttuu kiinnitetyllä määrällä ylös ja alas. Ainoastaan endogeenisiä muuttujia sisältävässä VAR-mallissa muutetaan endogeenisen muuttujan aikasarjan viimeistä havaintoa. Esimerkiksi BKT:n viimeisen vuosineljänneksen kasvuastetta voidaan muuttaa 0,5 prosenttiyksikköä ylöspäin, jolloin VAR-malli voidaan estimoida tällä uudella aikasarjalla. Tämän jälkeen suoritetaan dynaamiset out-of-sample-ennusteet normaalisti ja tarkastellaan, kuinka paljon mallin endogeenisten muuttujien ennustetut arvot muuttuvat. Keskeistä on, että vaikka vain yhdessä mallin muuttujassa olisi mittausvirhe, mallin kaikkien endogeenisten muuttujien ennustetut arvot muuttuvat.

Eksogeenisiä muuttujia sisältävässä VARX-mallissa endogeenisten muuttujien herkkyysanalyysi vastaa VAR-mallin tapausta. Eksogeenisellä muuttujalla herkkyysanalyysitarkastelu kuitenkin poikkeaa hieman endogeenisen muuttujan tapauksesta, sillä eksogeenisen muuttujan kasvuasteet eivät määräydy VAR-mallin sisällä vaan mallin ulkopuolelta. Kun endogeenisillä muuttujilla kasvuaste-ennuste on riippuvainen viimeisen neljännesvuoden havainnoista, eksogeenisen muuttujan ennustetut kasvuasteet saatetaan arvioida malliin jo ennen viimeisen neljännesvuoden havaintojen julkaisua. Voidaan esimerkiksi arvioida työvoimakustannusten kasvavan estimointiperiodin päätyttyä puoli prosenttia joka neljännesvuosi seuraavan kahden vuoden ajan (kasvuasteen kerroin 1,005). Jos työvoimakustannusten tämänhetkinen todellinen arvo on esimerkiksi 10 000 ja virheellinen arvo on 10 100, virheellisellä arvolla tehty ennuste eksogeenisen muuttujan tasosta periodilla  $i$  poikkeaa ”todellisesta” ennusteesta määrällä  $(10\ 100 - 10\ 000) \cdot 1,005^i$ . Toisin sanoen eksogeenisen muuttujan mittausvirhe jää vaikuttamaan eksogeenisiin arvoihin koko ennusteajanjakson ajaksi ilman vaimenemista. Sen sijaan mallin endogeenisten muuttujien mittausvirheiden synnyttämä vaikutus ennusteeseen saattaa vaimeta, kuten osalle muuttujista käy luvussa 5 esitetyissä tuloksissa. One-a-t-a-time-herkkyysanalyysiä endogeeniselle ja eksogeeniselle muuttujalle on havainnollistettu kaaviossa 4.4. Analyysin tuloksiin palataan alaluvussa 5.4.



*Kaavio 4.4. Herkkyysanalyysi endogeenisella ja eksogeenisella muuttujalla. Yllä esimerkkinä on mittausvirhettä sisältävän muuttujan out-of-sample-ennuste vuosille 2012 ja 2013. Analyysissä estimointiajanjakson viimeisen havainnon kasvuastetta 2011Q4 muutetaan kiinnitetyllä prosenttiyksiköllä ylös tai alas ja suoritetaan ennuste. Endogeenisellä mallilla mittausvirheestä seuraavat mallin kaikkien endogeenisten muuttujien ennustetut arvot määräytyvät VAR-mallin estimoitujen yhtälöiden mukaisesti. Eksogeenisen muuttujan tulevat arvot määräytyvät ARIMA:n tai harkinnan perusteella ja vaikuttavat sitä kautta mallin endogeenisten muuttujien ennustettuihin arvoihin. Herkkyysanalyysissä lasketaan muuttujan todellisella arvolla tehdyn kasvuaste-ennusteen ja mittausvirheen sisältävällä arvolla tehdyn kasvuaste-ennusteen erotus.*



## 5. EMPIIRISET TULOKSET VAR-MALLIEN VALINNASSA

Tämän tutkimuksen tavoitteena on hyödyntää VAR-mallia Palkansaajien tutkimuslaitoksen kevään ja syksyn ennusteissa. Siksi mallien estimoinneissa ja testiennusteissa jäljitellään kevään tai syksyn ennustetilannetta.

Kannustimena Suomen kansantaloutta selittävän VAR-mallin rakentamiseen on talouden keskeisten muuttujien ennustaminen tutkimuslaitoksen lyhyen aikavälin talousennustejulkaisuissa. Yleensä ennusteet julkaistaan kahdesti vuodessa. Vuoden viimeisen neljännesvuoden tietojen päivittyttyä julkaistaan kevään ennuste seuraavalle kahdelle kokonaiselle vuodelle eli kahdeksalle vuosineljännekselle. Syksyllä, kun vuoden toisen neljännesvuoden tiedot ovat päivittyneet, kevään ennustetta tarkennetaan jäljellä oleville kuudelle neljännesvuodelle.

Edellisessä luvussa on pohjustettu valintakriteereitä, joita malleihin sovelletaan. Tässä luvussa lukija pääsee seuraamaan valintakriteerien tuloksia. Kussakin alaluvussa kuvataan, millaisia malleja valintakriteerien avulla on tarkasteltu, ja mitkä näistä malleista ovat läpäisseet kunkin valintakriteerin ehdot. Täten vertailtavien mallien määrä vähenee, kun yhdestä valintakriteeristä edetään seuraavaan. Tässä luvussa parhaiten menestyneiden mallien määrä tiivistyy lopulta kolmeen malliin. Niistä kullakin tehdään luvussa 6 ennuste vuosille 2017 ja 2018.

Empiiristen tulosten esittämisjärjestys noudattaa edellisen luvun rakennetta. Mallin ensimmäisenä valintakriteerinä käytetään ennustetarkkuutta, joka arvioidaan kahden eri vertailualgoritmin avulla. Ennustetarkkuuteen perustuvassa mallin valinnassa saadaan eroteltua seitsemän mallia, joihin sovelletaan tämän jälkeen toista valintakriteeriä, talousteoreettista perustaa. Kriteeriä käsittelevässä osiossa esitellään tulokset mallien impulssivasteista ja Grangerin kausaalisuustestistä. Impulssivasteista ja Grangerin kausaalisuustesteistä talousteoreettisesti mielekkäitä tuloksia saaneita malleja tarkastellaan käyttäen kolmatta valintakriteeriä eli herkkyysanalyysiä.

### 5.1. Ennustetarkkuuteen perustuva mallin valinta

Tässä osiossa syvennyttään VAR-mallien valintaan hyödyntäen edellisessä luvussa esiteltyä RMSE-vertailualgoritmia, vuosikasvuasteeseen perustuvaa vertailualgoritmia sekä ARIMA:a. Edellä kuvaillun mukaisesti malleja vertaillaan keskenään ensin RMSE-vertailualgoritmilla, minkä lisäksi

mallien joukosta poistetaan sellaiset mallit, joiden ennusteet ovat olleet ARIMA:n ennusteita merkittävästi heikompia. Tämän jälkeen parhaiten menestyneitä malleja vertaillaan vuosikasvuasteeseen perustuvalla vertailualgorithmilla. Ennustetarkkuuden vertailu keskittyy ensisijaisesti BKT-muuttujien (BKT tai korjattu BKT) ennusteen tarkkuuteen, joskin vuosikasvuasteeseen perustuvassa algoritmissa tarkastellaan myös mallien muiden muuttujien ennustetarkkuutta.

Mallin spesifioinnissa käsitellään neljää teemaa: viiveen pituutta, estimointiajankohdan aloitusta, muuttujavalintaa ja funktiomuotoa. Viiveen pituuden ja estimointiajankohdan aloituksen valinnassa nojataan ennustetarkkuuden lisäksi aihepiirejä käsittelevään kirjallisuuteen. Viiveen pituus ja estimointiajankohdan aloitus on valittu RMSE-algoritmia käyttäen ja funktiomuoto vuosikasvuasteeseen perustuvaa vertailualgorithmia käyttäen. Muuttujat puolestaan valikoituivat ensin karkealla rajauksella RMSE-algoritmia hyödyntäen ja sen jälkeen tarkalla rajauksella vuosikasvuasteeseen perustuvaa algoritmia käyttäen.

### ***5.1.1. Viiveen pituuden valinta RMSE-algoritmilla***

VAR-mallissa viiveiden määrä vaikuttaa estimoitavien parametrien määrään. Kun mallissa on  $k$  muuttujaa ja  $p$  viivettä, ja kunkin viiveen kerroinmatriisi on  $k^2$ -matriisi ja vakiovektorissa on  $k$  alkia, estimoitavia parametreja on yhteensä  $k+pk^2$  kappaletta.

Luvussa 3 mainittiin Lütkepohlin suositus estimoitavien yhtälöiden määrän ja havaintojen määrän välisestä suhteesta. Huomataan, että annetulla havaintojen määrällä suositus on mahdollista täyttää vain hyvin pienellä viivemäärällä. Koska suositusta noudatetaan taloustieteellisessä tutkimuksessa vain vähäisesti (Allen & Fildes 2001), painottuu viiveen pituuden valinta myös tässä tutkimuksessa muihin tekijöihin. Lopullinen viivemäärä putoaa kuitenkin hyvin alhaiseksi jopa kuukausitason aineistoa käsiteltäessä, vaikka monissa tutkimuksissa estimointi aloitetaan pitkistä viiveistä (Allen & Fildes 2001).

Tässä tutkimuksessa malleilla tarkasteltiin eripituisia viiveitä 12 viiveestä alaspäin. Kustakin mallista tehtiin estimointeja eri määrällä viiveitä, minkä jälkeen suoritettiin out-of-sample-ennusteet BKT:lle tai korjatulle BKT:lle. Peräkkäisiä kahden vuoden ennusteita vertailtiin aikavälillä 2010–2016. RMSE-algoritmilla saaduista tuloksista ilmeni, että keskimääräinen ennustetarkkuus oli merkittävästi pienempi pitkien viiveiden malleissa kuin niissä malleissa, joissa viiveitä oli

korkeintaan neljä. Vaikka pitkien viiveiden mallit saattoivat silloin tällöin menestyä paremmin kuin lyhyiden viiveiden mallit, niillä oli keskimäärin taipumusta hajaantua keskenään ja erkaantua kauas toteutuneesta BKT:sta. Pitkien viiveiden mallien keskimääräinen ennustetarkkuus RMSE:llä mitattuna hävisi jopa ARIMA (1,1,2):lle. Yhden ja kolmen viiveen mallien kasvuaste-ennusteet antoivat keskenään hyvin samankaltaisia tuloksia kuudessa erilaisia muuttujia sisältäneessä VAR-mallissa. Kun mallien viivepituus nostettiin kuuteen tai kahteentoista, niiden tulokset muuttuivat keskenään hyvin ristiriitaisiksi: kahden vuoden kasvuaste-ennusteet poikkesivat toisistaan jopa etumerkiltään. Myös BIC suosi lyhyitä viiveen pituuksia pitkien viiveiden sijaan.

Jotta ennustemallien tuloksiin voitaisiin luottaa, on hyviä ennusteita tuottavien mallien tärkeää antaa keskenään samansuuntaisia ennustuksia. Viiveen pituuden vertailujen perusteella tutkimuksessa rakennettiin korkeintaan kolmen viiveen VAR-malleja. Suuressa osassa malleja ennusteiden RMSE-virheet tai vuosiennusteista lasketut neliövirheet olivat keskimäärin alimmillaan, kun viiveiden määrä pudotettiin yhteen.

### ***5.1.2 Estimoinnin aloitusperiodin valinta RMSE-algoritmilla***

Kuten luvussa 3 suositeltiin, havaintoja kerättiin mahdollisimman pitkältä ajanjaksolta, jotta suurista muuttujamääristä ja pitkistä viiveistä johtuva mallin yliparametrisointi voitaisiin välttää. Yllä käsitellyssä viiveen pituuden tarkastelussa sekä BIC että muutamilla malleilla tehtyjen ennusteiden RMSE-neliösummat näyttivät suosivan lyhyiden viiveiden käyttämistä malleissa. Tämä mahdollistaisi estimointiajanjakson kohtuullisen supistamisen ilman, että syntyisi mallin yliparametrisoinnin riski.

Allenin ja Fildesin (2001) mukaan ennustemallin estimoinnin perussääntönä on kerätä mahdollisimman pitkä aikasarja ja hyödyntää kaikkea käytettävissä olevaa aineistoa. Poikkeuksena artikkeli mainitsee voimakkaita rakennemuutoksia sisältävät aikasarjat, joilla ennustetarkkuus voi parantua, kun estimointi aloitetaan rakennemuutoksen jälkeen. Toisaalta Allen ja Fildes (2001) argumentoivat, että todellinen tiedon generointiprosessi ei muutu rakennemuutosten seurauksena, ja että approksimaatio tiedon generointiprosessista tarkentuu aikasarjan pituuden lähestyessä ääretöntä.

Estimoinnin aloitushetkeksi harkittiin vuoden 1990 ohella myös vuosia 1992 ja 1995. Estimoidulla vuodesta 1992 alkaen aineistosta olisi jäänyt pois Neuvostoliiton hajoaminen ja 1990-luvun lama. Vuodesta 1995 aloittaminen olisi merkinnyt, että myös aika ennen Suomen kuulumista

Euroopan unioniin olisi jäänyt pois. Nämä tapahtumat muovasivat Suomen lähihistoriaa ja talouden toimintaa niin merkittävästi, että rakennemuutos aikasarjassa oli mahdollinen. Aikasarjan supistaminen olisi pienentänyt havaintojen määrää 7,4–18,5 prosentilla.

Ennustetarkkuutta tarkasteltiin viidellä eri ajanjaksolla noin kahdellakymmenellä erilaisella mallilla siten, että kustakin muuttujayhdistelmästä tehtiin estimointi vuosista 1990 ja 1992 alkaen. Out-of-sample-ennusteiden perusteella estimoinnin vuodesta 1992 aloittavien mallien keskineliövirheen neliöjuurten summa oli keskimäärin 13 prosenttia suurempi kuin vuodesta 1990 estimoiduissa vastaavissa malleissa. Myöhemmin, kun vuodesta 1990 estimoinnin aloittavia malleja vertailtiin vuodesta 1995 estimoinnin aloittaviin malleihin, jälkimmäiset menestyivät entistä heikommin. Näyttäisi siltä, että 1990-luvun alussa tapahtuneet suuret yhteiskunnalliset ja taloudelliset muutokset eivät vääristä muuttujien parametristimaatteja. Sen sijaan kyseisen ajanjakson havainnot auttavat estimoimaan todellista tiedon generointiprosessia ja tarkentamaan estimointiajanjakson ulkopuolelle jääviä ennusteita.

### **5.1.3. Muuttujien valinta RMSE-algoritmilla**

Vaikka viiveiden määrä ja estimointiajanjakson aloitushetki ovatkin tärkeitä VAR-mallin onnistumisen kannalta tärkeitä, mallin sisältämien muuttujien valinta on onnistumisen määrittävä tekijä. Ennustevertailua varten tehtiin rajoittamattomia 3-6 muuttujan VAR-malleja erilaisilla korrelaatiotaulukoiden (liitteet 4 ja 5) ja talousteorian viitoittamilla muuttujayhdistelmillä sekä vaihtuvilla määrillä lyhyitä viiveitä. Tyypillisimmin mallien muuttujat sisälsivät joitain seuraavista muuttujista: *bkt*, *bktadj*, *i*, *bkt28*, *fi\_eu15*, *u\_seas*, *cur29* ja *bkt29*. Lisäksi osaan malleista sovitettiin aikatrendiä  $t$ . Malleissa epästationaaristen muuttujien aikasarjat muutettiin stationaariseksi ottamalla logaritmin differenssi.

Estimointi ja dynaaminen out-of-sample-ennuste suoritettiin alaluvussa 4.1.1. kuvatun tavalla. Muuttujia valittaessa tarkasteltiin ensisijaisesti BKT:n tai korjatun BKT:n ennusteita, sillä kyseisten muuttujien ennustetarkkuus katsottiin tärkeäksi.

RMSE-vertailualgoritmissa kustakin mallista tehtiin vuosittain out-of-sample-ennusteita ja useiden ennusteajanjaksojen BKT:n tai korjatun BKT:n ennusteiden RMSE:t summattiin vuosien yli. Mallit asetettiin paremmuusjärjestykseen luvussa 4 esitettyjen kriteerien perusteella.

RMSE-vertailualgoritmin avulla valtaosa malliehdokkaista saatiin pudotettua pois. Pienimmät

RMSE-summat saaneet mallit sisälsivät korkeintaan viisi seuraavista muuttujista: *dlogbkt*, *dlogbktadj*, *cur29*, *u\_seas*, *fi\_eu15*, *dlogi* ja *dlogbkt28*.

#### **5.1.4. Muuttujien valinta vuosikasvuasteeseen perustuvalla algoritmilla**

Parhaiten RMSE-vertailualgoritmissa menestyneille malleille suoritettiin vuosikasvuasteeseen perustuva algoritmi. Vuosikasvuasteeseen perustuvassa algoritmista neljännesvuosiennusteet aggregoitiin kahdeksi vuositason ennusteeksi. VAR-mallien ja ARIMA-mallin muuttujaennusteiden kunkin vuoden kasvuaste-ennusteista vähennettiin toteutunut kasvuaste ja mallien vuosittaisen kasvuasteen virhettä verrattiin ARIMA:n estimoidun kasvuasteen virheeseen.

Aluksi tarkasteltiin vain BKT:n ja korjatun BKT:n muuttujia. Ennustevertailuita tehtiin vuosien 2009–2016 välillä. Kun mallien absoluuttisia ennustevirheitä tarkasteltiin, korjatun BKT:n sisältävien mallien korjatun BKT:n vuosikasvuasteen ennuste erosi todellisesta kasvuasteesta 1,22 prosenttiyksikköä, kun taas BKT:n kasvuasteen ennusteet erosivat todellisesta kasvuasteesta keskimäärin 1,48 prosenttiyksikköä. Estimoidujen VAR-mallien ennustetarkkuus oli merkittävästi parempi kuin kilpailevan ARIMA-mallin ennustetarkkuus. Ennustevertailua jatkettiin vain korjatun BKT-sarjan sisältävillä malleilla.

Tätä tutkimusta koskeva työpaperi (Korhonen, 2018) käsittelee ennustevertailun etenemistä tutkimuksen aikana ja kuvailee ennustetarkasteluista pois karsittuja malleja yksityiskohtaisesti.. Vuosikasvuasteeseen perustuvan vertailualgoritmin perusteella pienimmät ennustevirheet sisältäneet mallit sisältävät muuttujia seuraavasti:

Malli 1. *dlogbktadj*, *dlogi*, *u\_seas*, *dlogbkt28*, *fi\_eu15*

Malli 2. *dlogbktadj*, *u\_seas*, *dlogbkt28*, *fi\_eu15*

Malli 3. *dlogbktadj*, *dlogi*, *dlogbkt28*, *fi\_eu15*

Malli 4. *dlogbktadj*, *dlogbkt28*, *fi\_eu15*

Malli 5. *dlogbktadj*, *dlogi*, *u\_seas*, *dlogbkt28*, *dloglcost*, *fi\_eu15*

Malli 6. *dlogbktadj*, *dlogi*, *dlogbkt28*, *dloglcost*, *fi\_eu15*

Malli 7. *dlogbktadj*, *dlogi*, *dlogbkt28*, *dloglcost*, *fi\_eu15*

Malleissa 1-6 on yksi viive ja mallissa 7 kaksi viivettä.

VAR-mallien 1–7 ennustetarkkuutta kuvataan liitteessä 6, johon malleista on koottu niiden korjatun BKT:n kasvuasteen keskimääräisten ennustevirheiden itseisarvot sekä ennustevirheiden neliösummat. Kahden vuoden ennusteissa mallien keskimääräinen BKT:n kasvuasteen ennustevirheen itseisarvo aikavälillä 2010–2016 oli 0,96: ensimmäisen vuoden ennuste oli keskimäärin 0,80 prosenttiyksikön päässä toteutuneesta, kun sitä vastoin toisen vuoden ennustevirheiden keskimääräinen itseisarvo oli 1,11 prosenttiyksikköä. Korostettakoon, että ennustevirheiden itseisarvot eivät sisällä tietoa virheiden jakauman symmetrisyydestä. Toisin sanoen niistä ei voida päätellä, ovatko ennusteet harhaisia.

Vuositasolla laskettujen kasvuasteiden ennustevirheiden neliösumma seitsemän mallin kesken on 18,83. Jos ennusteajanjakso 2009–2010 otetaan mukaan, keskimääräinen neliösumma nousee puolitoistakertaiseksi. Suuri ero neliösummassa johtuu siitä, että finanssikriisin odottamattoman vaikutuksen vuoksi vuosikasvuasteen ennusteet malleille poikkeavat merkittävästi toteutuneesta kasvuasteesta.

Mallien 1–7 vertailu vuosikasvuasteeseen perustuvalla vertailualgoritmilla toistettiin tekemällä puolentoista vuoden ennusteet. Korjatun BKT:n ennusteet olivat merkittävästi tarkempia, kun kahden vuoden ennusteista siirryttiin puolentoista vuoden ennusteisiin. Kuudessa yhden viiveen mallissa vuosikasvuasteen ennuste oli puolentoista vuoden ennusteiden kohdalla keskimäärin 0,44 prosenttiyksikön päässä toteutuneesta korjatun BKT:n kasvuasteesta vuosien 2010–2016 aikana. Kahden vuoden ennusteissa vastaava luku oli 0,96 prosenttia. Huomattavaa on myös se, että puolentoista vuoden ennusteissa viidellä mallilla seitsemästä ennuste toiselle vuodelle (3–6 vuosineljänneksen päähän) oli keskimäärin tarkempi kuin kahden vuoden ennusteissa ennuste ensimmäiselle vuodelle (1–4 vuosineljänneksen päähän). Mallien väliset ennustevirheiden itseisarvojen erot pysyivät hyvin pieninä kuuden vuosineljänneksen ennustevertailuissa.

Korjatun BKT:n ennustetarkkuuteen perustuvien vertailujen jälkeen tarkasteltiin EU-maiden BKT:n, kausitasoitettun työttömyysasteen, investointien sekä *fi\_eu15*:n ennusteita malleissa 1–7. Kullekin VAR-mallin muuttujalle oli estimoitu ARIMA (1,1,2), johon VAR-mallien antamia muuttujaennusteita verrattiin. Näissä malleissa EU-maiden BKT-ennuste poikkesi toteutuneesta EU-maiden BKT:sta keskimäärin 0,34 prosenttiyksiköllä. Se oli keskimäärin 2,5 prosenttia parempi kuin ARIMA:n ennuste EU-maiden BKT:lle ennustevirheiden neliösummalla mitaten. Mallien työttömyysasteiden antamat ennusteet hävisivät niukasti ARIMA:lle mutta olivat kauttaaltaan erittäin hyvät: estimoitu työttömyysaste (%) poikkesi todellisesta työttömyysasteesta keskimäärin

0,4 prosenttiyksikön verran. ARIMA:lle häviämistä voidaan selittää sillä, että työttömyysasteessa on merkittävää pysyvyyttä, mistä syystä ARIMA onnistui ennustamaan työttömyyden arvot erittäin hyvin.

Mallien investoinneille laskettu ennustevirheiden itseisarvo oli suurempi kuin aiemmin esiteltyjen muuttujien ennustevirheiden itseisarvo. Investointien ennustetut kasvuasteet poikkesivat toteutuneesta keskimäärin 1,9 prosenttia. Mallien investointien ennustevirheiden neliösumma oli lisäksi keskimäärin 7,7 prosenttia suurempi kuin vastaavan ARIMA:n ennustevirheiden neliösumma.

Heikoin ennuste oli Suomen ja EU15:n työntekijälle maksettujen nimellisten kompensatioiden suhdemuuttujalla  $fi\_eu15$ . Ennuste oli valtaosassa malleista systemaattisesti liian alhainen kaikilla ennusteajanjaksoilla vuosien 2010–2016 välillä. Yksittäisen mallin vuositasen ennustevirheiden neliösumma oli pahimmillaan kymmenkertainen  $fi\_eu15$ :n ARIMA:an (ARIMA1,1,2) verrattuna. Tätä selittänee  $fi\_eu15$ :n aikasarjan käyttäytyminen 1990-luvun laman aikana. Markan pakkodevalvaatio vuonna 1991 ja kelluminen vuodesta 1992 alkaen synnyttävät nimellisten kompensatioiden muuttuun merkittävän syvennyksen vuosien 1991 ja 1995 välillä. Vuosien 1991 ja 1995 välillä bruttokansantuotteen sarja aikasarjassa notkahtaa samaan aikaan alaspäin ja lähtee hitaasti nousuun. Mallin muuttujien estimointiajankaksolle sijoittuva käyttäytyminen vaikuttaa parametriestimaatteihin siten, että vuodesta 2009 alkanut taloudellisen toiminnan hidastuminen ennustaa nimellisten kompensatioiden suhteen voimakasta laskua. Nähtävästi malli ei kykene huomioimaan sitä, että markan kelluttamisen ja Euroopan talous- ja rahaliittoon liittymisen seurauksena nimellisten kompensatioiden  $fi\_eu15$  tuntuvaa alenemista ei kuitenkaan tapahtunut 2009 jälkeen.

#### **5.1.4. Funktiomuoto: VAR-malleista VARX-malleiksi**

Edellä ilmeni, että ennustevertailuissa vuodesta 2010 alkaen  $fi\_eu15$ :n ennusteet olivat systemaattisesti liian alhaiset. Kaikki RMSE-vertailualgorithmilla menestyneet mallit sekä niistä vuosikasvuasteeseen perustuvalla vertailualgorithmilla valitut mallit 1–7 sisältävät muuttujan  $fi\_eu15$ . Ennustevertailuissa muuttujan  $fi\_eu15$  pudottaminen pois VAR-mallista tai korvaaminen ainoastaan Suomen nimellisillä kompensatioilla tai Suomen työntekijää kohti lasketuilla kustannuksilla  $lcost$  heikensi korjatun BKT:n ennusteita merkittävästi.

VAR-mallin endogeenisuudesta syntyvä muuttujien takaisinkytkentä aiheuttaa sen, että yhden muuttujan havainnon muutos ennusteessa vaikuttaa mallin kaikkien muuttujien tuleviin ennustettuihin arvoihin. Toisin sanoen systemaattinen virhe yhden muuttujan ennusteessa voi palautua virheenä kaikkien mallin muuttujien ennusteissa. Tämä motivoi tarkastelemaan keinoja, joilla muuttujan  $fi\_eu15$  ennustetta voitaisiin tarkentaa.

Nimellisten kompensatioiden muuttuja  $fi\_eu15$  on varsin vakaa vuosien 1997–2006 sekä 2010–2016 välisenä aikana.  $fi\_eu15$ :n varianssi vuosien 2010–2016 aikana on 0,00011, kun keskiarvo on 1,10. Mikäli endogeeninen malli ennustaa virheellisesti  $fi\_eu15$ :n laskevan heti ensimmäisestä ennusteperiodista alkaen, tämä vaikuttaa kaikkiin tuleviin ennusteperiodeihin kaikkien muuttujien ennusteita heikentävästi.

Ongelma ratkaistiin muuttamalla  $fi\_eu15$  eksogeeniseksi muuttujaksi. Rajoittamattomien VAR-mallien sijaan estimoitiin alaluvussa 3.4. kuvatun kaltaisia VARX-malleja. Kunkin VARX-mallin estimointijaksolla käytettiin  $fi\_eu15$ :n toteutuneita arvoja, kun taas ennustejaksolla  $fi\_eu15$ :n ARIMA (1,1,2):n ennusteet syötettiin malliin eksogeenisina.  $fi\_eu15$ :n eksogeenisuus antaa mahdollisuuden myös harkinnanvaraiselle ennustamiselle: mikäli Suomen ja Euroopan unionin 15 maan työntekijälle maksettujen nimellisten kompensatioiden välisen suhteen kehityksestä on saatavilla informaatiota a priori, kehitysarvio voidaan syöttää malliin suoraan. Vastaava toimenpide olisi voitu tehdä myös työttömyysasteen tai Euroopan unionin BKT:n muuttujille. Niitä ei ole käsitelty tässä tarkastelussa siksi, että kummallakin muuttujalla endogeenisen VAR-mallin antamat ennusteet olivat ennustetarkoituksen näkökulmasta riittävän tarkkoja.

Kaikille seitsemälle mallille tehtiin uudet puolentoista vuoden ja kahden vuoden ennustetarkastelut siten, että eksogeeninen  $fi\_eu15$  esiintyi niissä joko alkuperäisenä arvonaan tai logaritmoituna. Malleja 1–7 vertailtiin siten, että muuttuja  $fi\_eu15$  oli niissä endogeenisena, eksogeenisena tai eksogeenisena ja logaritmoituna. Tulokset korjatun BKT:n ennustetarkkuudesta on koottu liitteeseen 6.

Puolentoista vuoden ennusteissa korjatun BKT:n ennustetut vuosikasvuasteet poikkesivat toteutuneesta korjatun BKT:n kasvuasteesta endogeenisilla  $fi\_eu15$ :n malleilla 0,44 prosenttiyksikköä, eksogeenisilla  $fi\_eu15$ :n malleilla 0,39 prosenttiyksikköä ja eksogeenisen logaritmoidun  $fi\_eu15$ :n malleilla 0,38 prosenttiyksikköä.

Ennusteiden heikentyminen on odotettua, kun puolentoista vuoden aikajänteeltä siirrytään kahden vuoden aikajänteelle. Sen sijaan eksogeenisen ja logaritmoidun eksogeenisen  $fi\_eu15$ :n



mallien korjatun BKT:n ennusteet eivät olleet endogeenisen mallin ennusteisiin verrattuna yksiselitteisesti parempia. Kasvuasteen ennustevirheen itseisarvot olivat keskimäärin lähes samat riippumatta muuttujan  $fi\_eu15$  endogeenisuudesta tai eksogeenisuudesta. Kun endogeenisilla malleilla vuositasen keskimääräinen ennustevirheen itseisarvo on 0,958 prosenttiyksikköä, ovat eksogeenisen ja eksogeenisen logaritmoidun  $fi\_eu15$ :n malleilla vastaavat luvut 0,954 ja 0,958 prosenttia. Huomattavaa on myös, että kahden vuoden ennusteissa jo ensimmäisen vuoden kasvuennuste oli kauempana toteutuneesta kuin puolentoista vuoden ennusteiden toisen vuoden kasvuennuste.

Lopuksi tarkasteltiin mallien muita endogeenisiä muuttujia. Euroopan unionin BKT:n ennustevirheet eivät muuttuneet juurikaan riippumatta siitä, oliko  $fi\_eu15$  endogeeninen, eksogeeninen vai eksogeeninen ja logaritmoitu. Sen sijaan investointien ennusteet keskimäärin heikkenivät hieman, kun  $fi\_eu15$  muutettiin eksogeeniseksi. Samoin kävi työttömyysasteen tason ennusteille, joskin ne olivat edelleen erittäin hyvät: sekä eksogeenisen että eksogeenisen logaritmoidun  $fi\_eu15$ :n malleilla vuosittaisen tason ennustevirhe oli puolentoista vuoden ennustevertailussa kahden desimaalin tarkkuudella 0,23 prosenttiyksikön päässä todellisesta arvosta. Lisäksi  $lcost$ in ennustettu vuosittainen kasvuaste poikkesi toteutuneesta kasvuasteesta 0,48 prosenttiyksikköä eksogeenisen  $fi\_eu15$ :n malleilla ja 0,27 prosenttiyksikköä eksogeenisen logaritmoidun  $fi\_eu15$ :n malleilla.

Ennustetarkkuuteen perustuvan valintakriteerin tuloksena valittiin VARX-mallit 1–7. Niiden muuttujat ja viiveet vastaavat edellä esiteltyjä VAR-malleja 1–7 sillä erotuksella, että VARX-malleissa 2 ja 5 muuttuja  $fi\_eu15$  on asetettu eksogeeniseksi muuttujaksi ja malleissa 1, 3, 4, 6 ja 7 eksogeeniseksi logaritmoiduksi muuttujaksi. Mallien yhtälöt on koottu liitteeseen 7. Vakaan ennustetarkkuuden varmentamiseksi VARX-malleille 1–7 tehtiin lopuksi uudet vuosikasvuasteeseen perustuvat ennustetarkkuuden vertailut vuosien 2000–2016 kattavalle ajanjaksolle. Mallien ennustetarkkuus oli yhtä hyvä pelkästään laskusuhdannetta ja hidasta kasvua sisältävällä ajanjaksolla 2010–2016 kuin sekä nousu- että laskusuhdannetta sisältävällä ajanjaksolla 2000–2016.

## 5.2. Tulokset impulssivasteista

Luvussa 4 selitettiin, miksi hyvä ennustetarkkuus ei ole tae siitä, että malli on talusteoreettisesti mielekäs ja että siihen voi luottaa. Siksi edellisessä alaluvussa parhaiten menestyneitä seitsemää

VARX-mallia tarkasteltiin toisena valintakriteerinä olevan taloustieteellisen mielekkyyden näkökulmasta. Tässä talousteoreettista mielekkyyttä selvittävässä osiossa tarkastellaan Grangerin kausaalisuustestin ohella myös impulssivasteita ennustevertailuissa parhaiten menestyneistä malleista.

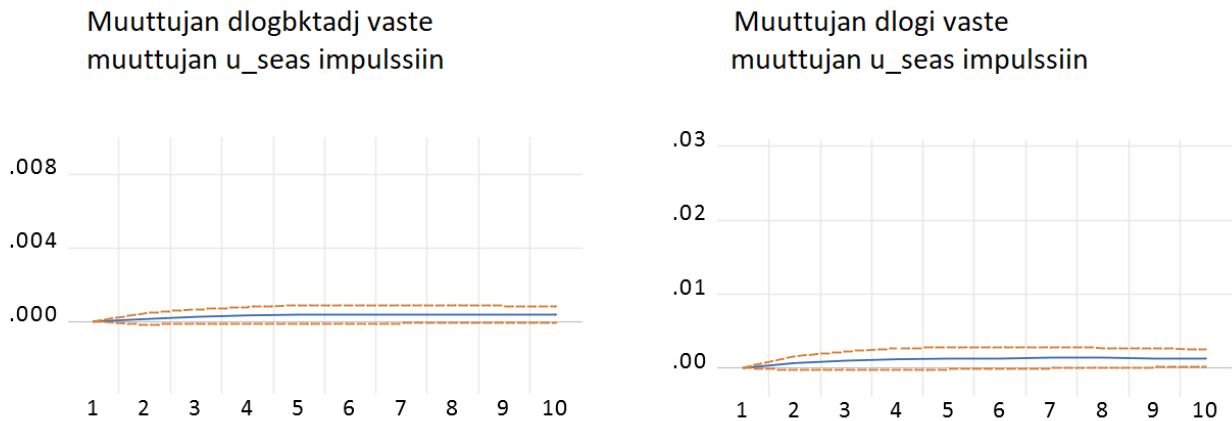
Talousteorian perusteella voidaan tehdä joitain oletuksia siitä, miten muiden mallin muuttujien pitäisi käyttäytyä yhden muuttujan shokin seurauksena. Mallin talousteoreettisesti johdonmukainen käyttäytyminen edellyttää esimerkiksi, että muuttujan oma shokki kasvattaa muuttujan omaa arvoa. Impulssivasteiden tuloksissa pitäisi lisäksi ilmetä, että korjattu BKT ja investoinnit vaikuttavat toisiinsa positiivisesti ja että *bkt28* vaikuttaa korjattuun BKT:hen ja investointeihin positiivisesti. Investointien vasteen arvellaan olevan voimakas muihin mallin muuttujiin verrattuna. Työttömyysasteen shokin edellytetään laskevan korjattua BKT:ta ja investointeja. Euroopan unionin BKT:n (*bkt28*) arvellaan reagoivan hyvin vähän mallin muiden muuttujien shokkeihin. Suomen työntekijää kohti laskettujen työvoimakustannusten shokin vaikutusta on vaikea arvioida, sillä kustannusten kasvun taustalla vaikuttaa useita tekijöitä.

Impulssivasteita on tarkasteltu seuraavasti. Kullekin mallille on asetettu yhteen muuttujaan kohdistuva muuttujan keskihajonnan suuruinen shokki, ja shokin aiheuttamat impulssivasteet on poimittu talteen. Impulssivasteet on poimittu mallien kaikista endogeenisistä muuttujista yksi kerrallaan. Muuttujan shokin synnyttämiä vasteita malliin on tarkasteltu shokkia seuraavien kymmenen vuosineljänneksen ajan.

Impulssivasteiden tuloksissa kaikille seitsemälle VARX-mallille on yhteistä, että muuttujan oma positiivinen shokki kasvattaa muuttujan omaa arvoa. Toisin sanoen esimerkiksi investointeihin syntyvä positiivinen shokki tällä periodilla saa investointien arvon pysymään tavallista korkeammassa arvossa myös seuraavalla periodilla. Toisaalta investointien ja BKT:n vasteissa shokki vaimenee sekä positiivisten että negatiivisten muutosten kautta.

Investoinnit ja BKT reagoivat toisiaan kasvattavasti kaikissa investointeja sisältävillä malleissa. Odotusten mukaisesti *bkt28* reagoi vähän tai ei lainkaan mallin muiden muuttujien shokkeihin, siinä missä sen oma shokki puolestaan vaikuttaa kaikilla malleilla korjattua BKT:ta ja investointeja kasvattavasti ja työttömyysastetta vähentävästi. *Lcost* ei itse näytä reagoivan mallin muissa muuttujissa tapahtuviin shokkeihin, mutta mallissa 6 *lcostin* oma shokki näyttäisi kasvattavan korjattua BKT:ta ja investointeja. Mallissa 7 *lcostin* shokit eivät näytä vaikuttavan muihin muuttujiin, eivätkä muiden muuttujien shokit näytä vaikuttavan *lcostiin*. Tätä voidaan

selittää sillä, että mallissa 7 *lcost* ei ollut t-testien perusteella tilastollisesti merkittävä.



*Kaavio 5.2. Korjatun BKT:n ja investointien vasteet työttömyyden shokkiin. Sininen käyrä osoittaa vasteen, punaiset käyrät ovat kahden keskihajonnan päässä vasteesta. Työttömyysmuuttujan sisältävien VARX-mallien impulssivasteiden perusteella työttömyyden positiivinen shokki vaikuttaa korjattua BKT:ta ja investointeja kasvattavasti. Työttömyysmuuttujan sisältävät VARX-mallit hylätään, koska niiden oletukset ovat talousteoreettisesti ongelmallisia.*

Työttömyyden aiheuttamien shokkien vaikutus korjatun BKT:n ja investointien vasteisiin näyttää talousteorian valossa ongelmalliselta. Kaikissa työttömyysasteen sisältävissä malleissa (mallit 1, 2 ja 5) työttömyysasteen positiivinen shokki eli mallin ulkopuolelta aiheutuva työttömyysasteen kasvu kasvattaa korjattua BKT:ta ja investointeja lievästi. Kaaviossa 5.2 on esimerkkinä mallin 2 korjatun BKT:n ja investointien vasteet työttömyyden positiiviselle shokille. Talousteorian mukaisesti työttömyyden kasvua pitäisi seurata taloudellisen aktiviteetin hidastumista eli BKT:n ja investointien kasvuasteen siirtymistä tasapainon alapuolelle. Työttömyysasteen impulssin kasvattava vaikutus BKT:n ja investointien vasteisiin on pieni, mutta talousteorian vastainen. Johtopäätöksenä mallit 1, 2 ja 5 jäävät pois VARX-ennustemallien joukosta, ja analyysiä jatketaan malleilla 3, 4, 6 ja 7.

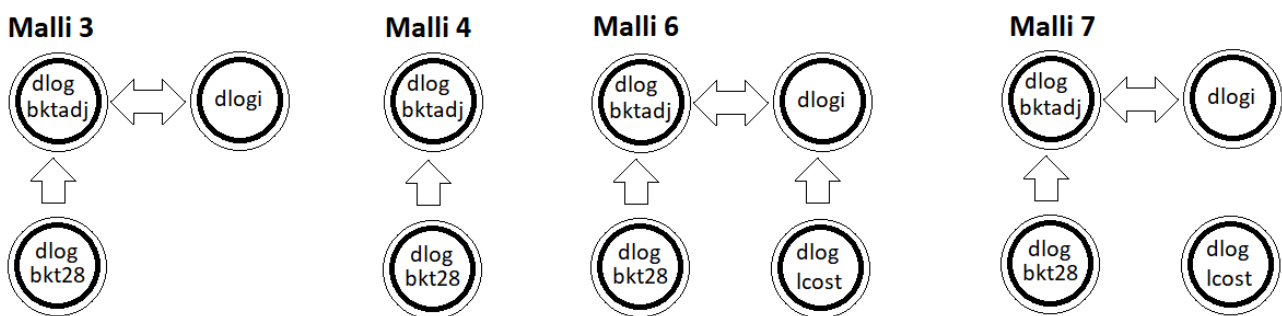
### 5.3. Tulokset Grangerin kausaalisuustesteistä

Impulssivasteet osoittavat shokin aiheuttamien muutosten suunnan ja suuruuden, mutta eivät ota kantaa muuttujien välisiin kausaalisuhteisiin. Mallin kannalta on keskeistä, että muuttujien välillä on tilastollista kausaalisuutta siten, että mallin kausaalisuhteiden verkko muotoutuu sivulla 36 esitellyssä kaaviossa 4.3. kuvatun kaltaisesti. Seuraavaksi pyritään selvittämään edellisessä luvussa kuvatulla tavalla, pystytäänkö muuttujan  $y_2$  arvoilla ennustamaan muuttujan  $y_1$  arvoja. Tämä käsitellään kullakin mallilla 3, 4, 6 ja 7 siten, että mallin kunkin muuttujaparin Grangerin

kausalisuustestit tehdään yksi kerrallaan. Vertailussa säilytetään vain sellaiset mallit, joissa muuttujien Granger-kausalisuhteiden verkko tukee VARX-mallien oletusta muuttujien välillä vallitsevasta takaisinkytkennästä.

Grangerin kausalisuustestien tuloksista arvellaan nousevan esiin muutamia varteenotettavia tekijöitä. Ensinnäkin *bkt28*:n epäillä olevan eksogeeninen, jolloin yksikään mallin muuttujista ei aiheuttaisi *bkt28*:aa. Lisäksi arvellaan, että investoinnit ja korjattu BKT saattavat Granger-kausalisuuden mielessä aiheuttaa toisensa. On myös syytä epäillä, että malli 7 karsiutuu pois Grangerin kausalisuustesteissä. Syynä tähän on se, että mallissa 7 *lcost* ei näytä reagoivan muiden mallien shokkeihin, eivätkä muut mallit reagoi *lcost*:n shokkeihin. Impulssivasteiden ja Grangerin kausalisuustestien yhteyttä käsiteltiin luvussa 4.2 sivuilla 31 ja 32.

Grangerin kausalisuustestien tulokset vastaavat pitkälti odotuksia. Kaikilla neljällä mallilla *bkt28* ja *lcost* ovat heikosti eksogeenisia eli mallin muut muuttujat eivät aiheuta niitä. *bkt28* aiheuttaa Granger-kausalisuuden näkökulmasta korjatun BKT:n arvot, muttei investointien arvoja. Kaikissa investoinnit sisältävissä malleissa 3, 6 ja 7 investointien ja korjatun BKT:n välillä on palautevaikutusta. Mikään muuttuja ei vaikuta *lcost*:iin, mutta mallissa 6 *lcost* vaikuttaa investointeihin 2,5 prosentin riskillä. Malli 7 sen sijaan jätetään pois, sillä siinä *lcost*:lla ei ole Granger-kausalisuhdetta yhdenkään muuttujan kanssa. Mallit 3, 4 ja 6 jatkavat herkkyysanalyysitarkasteluun.



Kaavio 5.3. Mallien 3, 4 ja 6 Grangerin kausalisuustestit vastaavat odotuksia VARX-mallien muuttujien välisestä dynaamisesta vuorovaikutuksesta. Mallissa 7 muuttujien välinen kausalisuhteiden verkko ei kata kaikkia muuttujia, vaan *lcost* jää ilman Granger-kausalisuhdetta muiden muuttujien kanssa. Malli 7 hylätään.

## 5.4. Tulokset herkkyysanalyyseistä

Mallien ennustetarkkuuteen ja taloustieteelliseen mielekkyyteen perustuvien valintakriteerien perusteella jäljellä ovat enää mallit 3, 4 ja 6, joiden yhtälöt on koottu liitteeseen 7. Tarkastellaan seuraavaksi tuloksia herkkyysanalyyseistä, joissa mallien luotettavuutta tutkittiin selvittämällä mallin muuttujien herkkyyttä mittausvirheille. Kullekin muuttujalle suoritettiin one-at-a-time herkkyysanalyysi alaluvussa 4.4. kuvatulla tavalla. Dynaamiset out-of-sample-ennusteet on tehty kuudella kahden vuoden mittaisella ajanjaksolla aikavälillä 2010-2016. Kullakin ajanjaksolla ennusteet on tehty viimeisen estimoitavan havainnon todellisella arvolla ja lisäksi positiivisen ja negatiivisen mittausvirheen sisältävillä arvoilla. Kullekin ennusteajanjaksolle on tällä tavoin suoritettu kolme ennustetta, joiden tuloksia on vertailtu keskenään.

Jotta mittausvirheiden vaikutusta ennusteisiin voitaisiin täsmällisesti arvioida, on herkkyysanalyysin vastattava seuraaviin kysymyksiin:

1. Kuinka suuriksi mallin kunkin muuttujan tyypilliset mittausvirheet arvioidaan?
2. Ovatko mittausvirheiden vaikutukset muuttujien ennusteisiin symmetrisiä? Vaikuttaako muuttujan negatiivinen mittausvirhe ennusteisiin itseisarvoltaan yhtä paljon kuin vastaavan suuruinen positiivinen mittausvirhe?
3. Ovatko mittausvirheiden vaikutukset lineaarisia?
4. Ovatko mallien ennusteet herkkiä jonkin tietyn muuttujan mittausvirheille?
5. Onko mallien välillä eroja siinä, kuinka herkkiä ne ovat saman muuttujan mittausvirheille?

Tässä osiossa tavoitteena on ensisijaisesti antaa lisätietoa ennusteiden vakaudesta, kun mittausvirheitä esiintyy. Mallien välinen karsinta on vain toissijainen tavoite. Jäljellä olevat mallit poikkeavat toisistaan vain siinä, onko niissä mukana investointien  $i$  tai työvoimakustannusten  $lcost$  muuttujaa. Jos jommankumman muuttujan mittausvirheet ovat tyypillisesti hyvin suuria ja nämä mittausvirheet vaikuttavat merkittävästi ennusteisiin, kyseisiä muuttujia sisältäviä malleja voidaan pitää heikompina verrattuna malleihin, joista investointien ja työvoimakustannusten muuttujat puuttuvat. Jos mallien välillä on eroja siinä, kuinka herkkiä ne ovat saman muuttujan mittausvirheille, herkästi muuttuva malli voidaan vastaavasti hylätä. Erityisesti kysymykseen 5 vastaaminen auttaa mallien karsinnassa.

Tarkastellaan herkkyysanalyysin avulla vastauksia yllä esitettyihin viiteen kysymykseen.

Mallien muuttujien mittausvirheistä ja niitä seuraavista tarkentumisista ei ole helposti saatavilla aikasarjoja. Tätä tutkimusta varten aikasarjat kerättiin kolmesti vuoden 2017 touko-kesäkuussa, syyskuussa sekä marraskuussa. Tämän tuloksena muuttujien vuoden 2016 ja 2017 tarkentuneet arvot saatiin tallennettua kahdesti. Tuloksista ilmenee, että muuttujille tyypilliset tarkentumisen suuruudet vaihtelevat jonkin verran periodeittain. Vuosina 2016 ja 2017 korjatun BKT:n kasvuaste muuttui tarkentumisen seurauksena keskimäärin 0,26 prosenttiyksikköä. *bkt28* ja *fi\_eu15* olivat keskimäärin varsin tarkasti arvioituja: päivitettyjen aikasarjojen kasvuasteet olivat keskimäärin *bkt28*:lla 0,03:n ja *fi\_eu15*:lla 0,06:n prosenttiyksikön päässä ensin julkaistusta kasvuastearviosta. *Lcost*:n tarkentunut arvo poikkesi keskimäärin 0,41 prosenttiyksikköä ensin julkaistusta arviosta. Investoinneilla vastaava luku oli 1,04 prosenttiyksikköä.

Olivatko mittausvirheiden vaikutukset symmetrisiä? Kysymykseen vastaamista varten mallien kaikille muuttujille tehtiin symmetriset herkkyystarkastelut. Kaikilla malleilla esimerkiksi investointien aikasarjan ennusteajanjaksoa edeltävän viimeisen periodin kasvuastetta nostettiin tai laskettiin 0,5 prosenttiyksikköä. Tämän jälkeen suoritettiin ennusteet +0,5 prosenttiyksikön sekä -0,5 prosenttiyksikön mittausvirheillä sekä alkuperäisellä investointien arvioidulla kasvuasteella. Jos mittausvirheiden vaikutukset olisivat symmetrisiä, +0,5 prosenttiyksikön ja -0,5 prosenttiyksikön mittausvirheillä tehtyjen ennusteiden pitäisi olla yhtä kaukana alkuperäisellä investointien arvioidulla kasvuasteella tehdystä ennusteesta. Jos etäisyydet ovat yhtä suuret, niistä lasketun osamäärän on oltava 1. Kysymystä symmetrisyydestä selvitettiin syöttämällä malliin symmetrisiä mittausvirheitä BKT:ssä ja investoinneissa ja määrittämällä niiden vaikutukset mallin kaikkien endogeenisten muuttujien ennusteissa. Tuloksista ilmeni, että kullakin muuttujalla edellä mainittujen etäisyyksien osamäärä oli neljän desimaalin tarkkuudella 1,0000. Tämän perusteella arvioidaan, että ennustevirheet ovat symmetrisiä.

Ovatko mittausvirheiden vaikutukset lineaarisia? Mittausvirheen lineaarinen vaikutus ennusteisiin mahdollistaisi sen, että one-at-a-time-herkkyyksianalyysin tulokset 0,5 prosenttiyksikön mittausvirheellä olisivat suoraan käytettävissä, kun lasketaan minkä tahansa suuruisen mittausvirheen vaikutusta. Jos vaikutukset ovat lineaarisia, 0,5 prosenttiyksikön mittausvirheestä arvioidun ennusteen ja todellisella arvolla tehdyn ennusteen erotus pitäisi olla viisinkertaisia suhteessa 0,1 prosenttiyksikön mittausvirheestä tehdyn ennusteen ja todellisella arvolla tehdyn ennusteen erotukseen. Vastaavasti 1,5 prosenttiyksikön mittausvirheellä tehdyn ennusteen pitäisi olla kolme kertaa kauempana todellisella arvolla tehdystä ennusteesta kuin 0,5 prosenttiyksikön mittausvirheellä tehdyn ennusteen. Investoinneille tehtiin herkkyyksianalyysit 0,1:n, 0,5:n ja 1,5:n

prosenttiyksikön mittausvirheillä. Herkkyysanalyysissä ennustettuja kasvuasteita verrattiin todelliseen ennusteeseen. 0,5 prosenttiyksikön virheet olivat 5,000-kertaisia 0,1 prosenttiyksikön virheisiin verrattuna. 1,5 prosenttiyksikön virheet olivat kolmen desimaalin tarkkuudella 3,000-kertaisia suhteessa 0,5 prosenttiyksikön virheisiin nähden. Lisäksi korjatulle BKT:lle, Euroopan unionin BKT:lle sekä *fi\_eu15*:lle tehtiin herkkyysanalyysit 0,1 prosenttiyksikön ja 0,5 prosenttiyksikön mittausvirheillä. Näillä muuttujilla lineaarisuus ei ollut yhtä tarkkaa, joskin selvästi havaittavissa. Korjatulla BKT:lla 0,5 prosenttiyksikön virheet olivat 5,011-kertaisia 0,1 prosenttiyksikön virheisiin. Euroopan unionin BKT:lla ja *fi\_eu15*:lla vastaavat kertoimet olivat 5,012 ja 4,989. Vaikuttaisi siltä, että tarkentumisen suuruuden vaikutus ennusteeseen on jokseenkin lineaarinen, ja että herkkyysanalyysin tuloksilla voidaan selvittää minkä tahansa suuruisen mittausvirheen vaikutus ennusteeseen.

Ovatko mallin muuttujat herkkiä jonkin tietyn tyyppisen muuttujan mittausvirheille? Liitteeseen 8 on koottu muutokset, jonka 0,5 prosenttiyksikön suuruinen mittausvirhe kunkin mallin muuttujan kasvuasteessa on aiheuttanut. Kun vaikutusta korjatun BKT:n ennusteeseen tarkastellaan, nähdään, että 0,5 prosenttiyksikön suuruinen mittausvirhe *bkt28*:n kasvuasteessa aiheuttaa kaikista suurimman ennusteen muutoksen. *Bkt28*:n kasvuasteen 0,5 prosenttiyksikön mittausvirhe harhauttaa korjatun BKT:n kasvuaste-ennustetta 0,84 prosenttiyksikköä 1. vuonna ja 0,50 prosenttiyksikköä toisena vuonna. Seuraavaksi suurin vaikutus on korjatun BKT:n kasvuasteen omilla mittausvirheillä (kasvuaste-ennuste muuttui ensimmäisenä vuonna 0,31 prosenttiyksikköä ja toisena vuonna 0,02 prosenttiyksikköä). Näiden jälkeen korjatun BKT:n kasvuaste-ennustetta eniten herkistävät muuttujat ovat järjestyksessä *lcost*, *fi\_eu15* ja investoinnit. Kun tarkastellaan eri muuttujien 0,5 prosenttiyksikön suuruisen kasvuasteen mittausvirheen vaikutusta investointien ennusteisiin, muuttujien herkkyysjärjestys on jokseenkin sama kuin korjatun BKT:n mittausvirheissä. Investointien ennuste on herkin *bkt28*:n mittausvirheille, joiden jälkeen vastaavat muuttujat ovat järjestyksessä *lcost*, investoinnit, korjattu BKT ja viimeisenä *fi\_eu15*. On huomattava, että mittausvirheen sisältävällä aineistolla tehty ennuste ei lähde karkaamaan, vaan virheellisestä arviosta tehty ennuste on toisena vuonna lähempänä todellisella arvolla tehtyä ennustetta kuin ensimmäisenä vuonna.

Toisaalta mallien herkkyyttä eri muuttujille tarkasteltaessa on huomattava, että vuosien 2016-2017 tarkentumisten suuruudet poikkeavat paljon eri muuttujien välillä. Selvitetään kunkin muuttujan tyypillisen suuruisen mittausvirheen vaikutus mallien ennusteisiin. Tämä voidaan tehdä suoraan jakamalla, sillä aiemmin mittausvirheiden vaikutusten malliin todettiin olevan lineaarisia.

Kun tarkastellaan BKT-ennusteiden muutoksia mallin kullekin muuttujalle tyypilliseksi katsotuilla (vuosien 2016–2017 keskimääräisillä) mittausvirheillä, suurimmat muutoksen aiheuttavat muuttujat ovat BKT:n ja investointien mittausvirheet. Tämän jälkeen eniten vaikuttavat *lcost* ja *bkt28*, joskin molemmilla muuttujilla vaikutus BKT-ennusteeseen on vaatimaton: *lcost* muuttaa korjatun BKT:n kasvuaste-ennustetta ensimmäisenä vuonna 0,09 prosenttiyksikköä ja *bkt28* 0,05 prosenttiyksikköä. Tyypillinen *fi\_eu15*:n kasvuasteen mittausvirhe muuttaa BKT-ennustetta prosenttiyksikön sadasosan verran. Tyypillisen kokoiset virheet vaikuttavat investointeihin suuruusjärjestyksessä investoinnit, *lcost*, korjattu BKT, *bkt28* ja viimeisenä *fi\_eu15*. Huomattavaa on, että vaikka *fi\_eu15*:n mittausvirhe vaikuttaa muuttujan *fi\_eu15* eksogeenisina annettuihin arvoihin koko ennusteperiodilla (jolloin eksogeeniset arvot ovat koko ennusteperiodin ajan virheellisiä), tämä puolestaan harhauttaa ennustetta hyvin vähäisesti.

Onko mallien välillä eroa siinä, kuinka herkkiä ne ovat muuttujan  $y_i$  mittausvirheille? Tälle ei löydetty tukea herkkyysanalyysitarkasteluissa, sillä mallien väliset erot ennusteiden herkkyydessä olivat erittäin vaatimattomia. Eksakti tarkastelu vaatisi herkkyyksien jakaumien tuntemista ja tilastollista testausta, jotka jäävät tämän tutkimuksen ulkopuolelle.

Herkkyysanalyysin tulosten tarjoama informaatio ei juurikaan tue yhdenkään yksittäisen mallin valitsemista. Tärkeä tulos on se, että mallin muuttujien suuri määrä yksinään ei näytä tekevän mallista erityisen herkkää mittausvirheille. BKT:n 0,5 prosenttiyksikön mittausvirheet vaikuttavat BKT-ennusteeseen kolmen muuttujan mallissa 3 yhtä paljon kuin viiden muuttujan mallissa 6 prosenttiyksikön kymmenesosan tarkkuudella mitattuna. Yleisesti ottaen tietyn muuttujan mittausvirhe vaikuttaa malleihin samalla suuruudella riippumatta mallin muiden muuttujien määrästä. Toisin sanoen viiden muuttujan mallissa neljän muuttujan täsmällinen arviointi ei puskuroi mallia mittausvirheiltä paremmin kuin se, että kolmen muuttujan mallissa kaksi muuttujaa tulee täsmällisesti arvioituksi.



## 6. ENNUSTEET VUOSILLE 2017 JA 2018

### 6.1. VARX-mallien ennusteet

Tehdään malleilla 3, 4 ja 6 ennusteita vuosille 2017 ja 2018. Estimoidaan VARX-malli päätymään juuri ennen ennustejakson alkua ja ajetaan sen jälkeen dynaaminen ennuste. Koska ennustelaitosten arviot talouden kehityksestä ovat vuoden 2017 ensimmäisen vuosineljänneksen julkistamisen jälkeen muuttuneet optimistisemmiksi ja talouden kasvuennusteita on korjattu ylöspäin, vertaillaan ennusteita 2017Q1 alkavalla kahdeksan neljännesvuoden jaksolla (estimointi päättyy 2016Q4), 2017Q2 alkavalla seitsemän neljännesvuoden jaksolla (estimointi päättyy 2017Q1) sekä 2017Q4 alkavalla viiden neljännesvuoden jaksolla (estimointi päättyy 2017Q3). 2017Q1 ja 2017Q2 alkavien ennusteiden estimoinneissa käytetään heinäkuussa 2017 päivitettyjä aikasarjoja. Ennusteiden odotetaan muuttuvan myönteisemmiksi vuoden edetessä.

Eksogeenisen muuttujan  $fi\_eu15$  arvot ennusteajanjaksolla on generoitu kolmea eri keinoa käyttäen. 2017Q1 alkavissa ennusteissa  $fi\_eu15$ :lle on syötetty ARIMA (1,1,2):n generoimat arvot. Lisäksi 2017Q1 alkavissa ennusteissa mallista 3 on tehty harkintaa hyödyntävä ennuste, jossa  $fi\_eu15$ :n arvioidaan laskevan vuosina 2017-2018 puoli prosenttia joka neljännesvuotena. Kutsutaan mallia, joka tällä tavoin olettaa Suomen nimellisten kompensatioiden maltillisen kehityksen, maltilliseksi malliksi 3. 2017Q2 ja 2017Q4 alkavissa ennusteissa hyödynnetään vain harkintaa eikä lainkaan ARIMA:n ennustamia arvoja. Kyseisissä ennusteissa eksogeenisen muuttujan  $fi\_eu15$  aikasarjana käytetään AMECO:n ennusteeseen perustuvaa aikasarjaa.

Ennusteet vuosille 2017 ja 2018 on kerätty liitteeseen 9. Taulukosta nähdään, että BKT:n kasvuasteeksi ennustetaan vuodelle 2017 keskimäärin 1,6 prosenttia. Tämä perustuu vuoden 2016 lopussa päättyviin endogeenisten muuttujien tietoihin ja oletukseen, että eksogeenisen muuttujan  $fi\_eu15$  kehitys noudattaa ARIMA (1,1,2):ta. Seuraavana vuonna kasvun odotetaan hidastuvan 0,7 prosentin vuosivauhtiin. Verrataan mallin 3 ARIMA:lla ja harkinnalla valittuja  $fi\_eu15$ :n arvoja vuosille 2017 ja 2018. Tällöin huomataan, että ennusteet vuoden 2017 kasvuasteille ovat prosentin kymmenesosan tarkkuudella samat. Vuonna 2018 harkintaa hyödyntävät ennusteet ovat hiukan optimistisemmat kuin ARIMA:a hyödyntävät ennusteet. Sovittamalla ARIMA:n antamat arvot eksogeenisen muuttujan  $fi\_eu15$  tuleviksi arvoiksi EU-maiden BKT:n kasvuasteet vuosille 2017 ja 2018 ovat 1,8 ja 1,3 prosenttia ja investointien kasvuasteet 2,8 ja -0,7 prosenttia. Suomen työntekijää kohti laskettujen työvoimakustannusten keskimääräinen ennustettu kasvuaste on

vuodelle 2017 2,2 prosenttia, mistä se kiihtyy 2,9 prosenttiin.

Katsotaan seuraavaksi mallien 3, 4 ja 6 ennusteita siten, että sisällytetään vuoden 2017 ensimmäinen neljännes malliin ja aloitetaan ennuste toisesta vuosineljänneksestä. Taulukosta käy ilmi, kuinka paljon optimistisemmaksi ennuste muodostuu nyt. Korjatun BKT:n kasvuaste vuodelle 2017 ennustetaan olevan 2,7 prosentin luokkaa, mistä se muuttuu vuonna 2018 maltillisemmaksi eli putoaa 0,9 prosenttiin. *Bkt28*:n kasvuasteet vuosille 2017 ja 2018 ovat niin ikään 1,9 ja 1,4 prosenttia. Investoinnit kiihtyvät voimakkaasti 9,2 prosentin kasvuun, josta ne madaltuvat 0,8 prosenttiin vuonna 2018. Odotetut kasvuasteet Suomen työvoimakustannuksissa työntekijää kohti ovat 1,0 ja 3,0 prosenttia.

Vuosien 2017 ja 2018 ennuste muuttuu sitä optimistisemmaksi, mitä pidemmälle vuosi 2017 etenee. Oletetaan edelleen eksogeenisen muuttujan *fi\_eu15* noudattavan ARIMA (1,1,2):n estimoimia arvoja ennusteajanjakson aikana, ja sisällytetään estimointiin vuoden kolmen ensimmäisen kvartaalin havainnot. Periodilta 2017Q4 alkavat ennusteet arvioivat keskimäärin EU-maiden BKT:lle 2,4 prosentin kasvua vuodelle 2017 ja 1,9 prosentin kasvua vuodelle 2018. Korjatun BKT:n kasvuasteiksi ennustetaan 3,1 ja 1,8 prosenttia. Investointien ennustetaan kasvavan vuonna 2017 10,9 prosenttia ja vuonna 2018 3,2 prosenttia. Työntekijää kohti laskettujen työvoimakustannusten odotetaan nousevan maltillisesti 0,1 prosenttia, mistä nousu kiihtyy 2,4 prosenttiin.

## 6.2. Ennusteiden luottamusvälit

Talousennusteet ovat yleensä vain piste-estimaatti muuttujien tulevista arvoista, eivätkä ne ota kantaa ennusteiden jakaumiin. Ennusteiden luottamusvälejä voidaan kuitenkin arvioida useita erilaisia menetelmiä käyttäen. Eräs havainnollinen vaihtoehto on hyödyntää out-of-sample-ennusteiden ennustevirheistä laskettuja keskihajontoja (Stock ja Watson 2007, 548–549). Menetelmään sisältyy ennustevirheeseen ja mallin parametrien estimointiin liittyvä epävarmuus.

Menetelmässä oletetaan, että ennustevirheet  $u_{T+1}$  ovat normaalisti jakautuneita. Tällöin ennusteen  $\alpha$ :n prosentin luottamusväli on muotoa:

$$\hat{Y}_{t+1|T} \pm z_{\alpha} SE(Y_{T+1} - \hat{Y}_{t+1|T}) \quad , \text{ missä}$$

$z_{\alpha}$  on testisuureen  $z$  kriittinen arvo  $1-\alpha$  prosentin riskitasolla

$SE(Y_{T+1} - \hat{Y}_{t+1|T})$  on out-of-sample-ennusteista laskettu ennustevirheiden otoskeskihajonta. (Stock & Watson 2007, 549.)

Luottamusvälilaskentaa sovellettiin mallin 6 korjatun BKT:n ennusteeseen, jonka mukaan kasvuaste vuodelle 2017 olisi 1,5 ja vuodelle 2018 0,6 prosenttia. Korjatun BKT:n ennustevirheiden keskihajonnat laskettiin periodista  $q_1$  alkaville kahdeksan vuosineljänneksen out-of-sample-ennusteille sekä periodista  $q_3$  alkaville kuuden neljännesvuoden out-of-sample-ennusteille. Kumpaankin out-of-sample-ennusteiden otokseen kuului 17 ennusteajanjaksoa vuosien 2000–2017 ajalta. On huomioitava, että otoksien pieni koko vähentää luottamusväliestimaattien luotettavuutta. Otoksista laskettiin keskihajonnat ensimmäisen ja toisen vuoden ennustevirheille erikseen. Periodista  $q_1$  alkavissa ennusteissa ennustevirheiden otoskeskihajonta oli ensimmäisen vuoden ennusteissa 1,34 ja toisen vuoden ennusteissa 2,95. Periodista  $q_3$  alkavissa ennusteissa vastaavat luvut olivat 0,34 ja 2,30. Esimerkiksi  $q_1$  alkavan ennusteen 50 ja 75 prosentin luottamusvälien ala- ja ylärajat vuodelle 2017 ovat tällöin:

$$1,5 \mp z_{50} \times 1,34 = (0,6 ; 2,4)$$

$$1,5 \mp z_{75} \times 1,34 = (-0,1 ; 3,0) .$$

Tuloksista huomataan, että periodista  $q_2$  alkava ennuste vuoden 2017 kasvuasteelle (2,7 %) on periodista  $q_1$  alkavan ennusteen 50 prosentin luottamusvälin ulkopuolella. 75 prosentin luottamustasolla periodista  $q_2$  alkava ennuste jää puolestaan  $q_1$  alkavan ennusteen luottamusvälin sisäpuolelle.

## 6.2. Muut Suomea koskevat talousennusteet

Edellä huomattiin, kuinka vuoden 2017 havaintojen sisällyttäminen estimoitavaan sarjaan muutti BKT:n ja investointien ennusteita myönteiseen suuntaan. Muutos noudattaa samaa linjaa usean Suomen kansantaloutta ennustavan julkaisijan kanssa: Palkansaajien tutkimuslaitoksen ja Etlan BKT:n kasvuaste-ennusteet vuodelle 2017 nousivat keväällä ennustetuista 1,9 prosentista ja 1,7 prosentista syksyllä ennustettuihin 3,6 ja 2,9 prosentin kasvuasteisiin (Ilmakunnas 2017a, 2017b; Kotilainen 2017b, Berg-Andersson, Kaitila & Kaseva 2017; Finanssiala 2017). Vastaavasti Nordea ja Valtiovarainministeriö kaksinkertaistivat BKT:n kasvuennusteensa vuodelle 2017 saman vuoden kesäkuussa (Valtiovarainministeriö 2017; Nordea 2017; Finanssiala 2017). VARX-mallien 2017Q4 alkava keskimääräinen BKT-ennuste vuodelle 2018 (1,8 %) on kuitenkin hieman vaatimattomampi

kuin edellä mainituilla julkaisijoilla (PT 2,5 %, Etlä 2,0 %, Nordea 2,0 % ja VM 2,1 %) (Finanssiala 2017). Neljästätoista Suomen talouden ennusteita julkaisevasta laitoksesta jokainen ennustaa investointien kasvun hidastuvan vuonna 2018: keskimääräinen kasvuaste-ennuste laskee vuoden 2017 6,46 prosentista 3,45 prosenttiin vuodelle 2018 (Finanssiala 2017). VARX-mallit ennustavat investointeihin merkittävästi suurempaa vaihtelua: 2017Q4 alkavista ennusteista vuoden 2017 keskimääräinen ennuste 10,9 prosenttia on korkeampi kuin yhdelläkään muulla ennustelaitoksella, kun taas vuoden 2018 ennuste 3,2 prosenttia on pessimistisimpien ennusteiden joukossa.

## 7. YHTEENVETO

Tutkimuksessa estimoitiin lukuisia Suomen kansantaloutta selittäviä malleja. Mallien ennustetarkkuuteen, makrotalousteoreettiseen mielekkyyteen sekä herkkyyksanalyysiin perustuvilla kriteereillä erotettiin kolme mallia, joilla tehtiin talousennuste vuosille 2017 ja 2018. Ennustemalleiksi valittiin kolme VAR-mallien täysin endogeenisestä muuttujakokoonpanosta poikkeavaa VARX-mallia. Niissä eksogeenisena muuttujana oli Suomen ja EU15:n nimellisten kompensatioiden suhde. Mallien endogeenisina muuttujina olivat korjattu BKT, EU-maiden BKT sekä mahdollisesti investoinnit tai sekä investoinnit että työvoimakustannukset työntekijää kohti. Malleja voidaan käyttää talouden ennustamiseen yhdessä tai erikseen.

Rakennettuihin VARX-malleihin sisältyy muutamia keskeisiä puutteita. RMSE-vertailualgorithmilla hylättiin kaikki mallit, joilla korjatun BKT:n ennuste oli RMSE:llä mitattuna merkittävästi epätarkempi kuin ARIMA (1,1,2):n ennuste yhdelläkään ennusteajanjaksolla. Tämä suhteellisen ankara kriteeri pudotti tarkastelusta sellaisia malleja, joiden keskimääräinen ennuste oli hyvä verrattuna muihin malleihin, mutta jotka ennustivat yhtenä tai kahtena vuonna heikosti. Jos tällaisten mallien viiveitä tai muuttujien funktiomuotoa olisi muutettu, niiden ennustetarkkuus olisi saattanut tarkentua riittävästi ollakseen parempi kuin ARIMA:n ennustetarkkuus.

RMSE-vertailualgorithmilla mallien ennusteiden RMSE-virheiden erojen tilastollisuutta merkitystä ei testattu. Ei siis ole selvää, ovatko erot mallien RMSE-tunnusluvuissa tilastollisesti merkittäviä. RMSE-erojen tilastollista merkittävyyttä voidaan testata Diebold–Mariano-testillä (ks. esim. Harvey, Leyborne & Newbold, 1997).

Korostettakoon sitä, että mallien valinnassa painotettiin korjatun BKT:n ennusteen tarkkuutta. On mahdollista, että käytettäessä korjatun BKT:n ennustetarkkuutta valintakriteerinä joukosta on pudonnut korjattua BKT:ta kohtalaisen hyvin ennustaneita malleja, jotka ennustivat mallin muita muuttujia erittäin hyvin.

Residuaalin autokorrelaatiotesteissä paljastui, että malli 3 olisi vaatinut kaksi viivettä autokorrelaation poistoon yhden viiveen sijaan. Tässä tutkimuksessa malli 3 on kuitenkin kuljetettu ennustetarkastelun läpi vain yhdellä viiveellä. Vastaisuudessa suositellaan tarkastelemaan mallin 3 ennusteiden tarkkuutta kahdella viiveellä. Lisäksi optimaalisen viiveen pituuden tarkastelu BIC:llä tai ennusteen tarkkuudella mitattuna suoritettiin vain endogeenisiä muuttujia sisältäville VAR-malleille. Optimaalinen viiveiden määrä on saattanut muuttua, kun eksogeeninen Suomen ja

EU15:n nimellisten kompensatioiden suhteen muuttuja sisällytettiin malliin endogeenisen muuttujan sijaan.

Kaiken kaikkiaan tässä tutkimuksessa rakennettujen VAR- tai VARX-mallien spesifikaatiota voi kehittää monin tavoin. Tutkimuksessa muuttujien aikasarjojen saatavuuteen liittyi rajoituksia, joita ei toistaiseksi ole saatu ratkaistua. Tietyt aikasarjat ovat toistaiseksi saatavilla vain kapealta aikaväliltä. Näitä ovat Suomen hintakilpailukykyä eksaktisti kuvaava työvoimakustannukset tuntia kohti sekä työttömyysasteen kanssa voimakkaasti korreloiva yksityisen velan BKT-osuuden muutos. Tutkimus- ja kehittämistoiminnan menot ja henkisten omaisuustuotteiden nettokanta puolestaan päivittyvät toistaiseksi hitaasti. Malleihin 1, 3, 5, 6 ja 7 sovitettiin investointimuuttujan tilalle tutkimus- ja kehittämistoiminnan menojen (T&K) tai henkisten omaisuustuotteiden nettokannan muuttujia. T&K-muuttujan tai henkisiä omaisuustuotteita sisältävät mallit menestyivät yhtä hyvin tai paremmin kuin investoinnit sisältävät mallit mitatessa vuosikasvuasteeseen perustuvalla algoritmilla. Muuttujia ei voitu sisällyttää malliin niiden hitaan päivittymisen vuoksi; kesäkuussa 2017 aikasarjat päättyivät vuoteen 2015. Mikäli muuttujia pystytään vastaisuudessa luotettavasti estimoimaan jollain lyhyellä viiveellä päivittyvällä mittarilla, voidaan tätä mittaria hyödyntämällä parantaa VAR- tai VARX-mallin korjatun BKT:n ennusteita entisestään.

Valuuttakorimuuttujan tai vientikorimuuttujan sisällyttäminen VAR-malliin heikensi korjatun BKT:n ennusteita merkittävästi. Kuten luvussa 3 on kuvailtu, valuutta- ja vientikori rakennettiin käyttämällä Suomen vientituotteiden 29 suurimmalle ostajamaalle vakiopainoja. Vakiopainot oli laskettu viejämaiden suhteellisten vientiosuuksien vuosien 2010–2016 keskiarvona. Todellisuudessa suomalaisia hyödykkeitä eniten vievien 29 maan kokoonpano sekä kunkin maan viennin suhteellinen osuus vaihtelevat vuosittain (ks. esim. Tulli 2005, 2010, 2015). Vaihtuvilla painoilla rakennetut indeksimuuttujat saattavat sopia VAR- tai VARX-malliin paremmin kuin kiinteillä painoilla lasketut muuttujat.

## LÄHTEET

- Ager, P., Kappler, M., & Osterloh, S. (2009). The accuracy and efficiency of the Consensus Forecasts: A further application and extension of the pooled approach. *International Journal of Forecasting*, 25(1), 167–181.
- Allen, P. G. & Fildes R. (2001). ”Econometric Forecasting” teoksessa Armstrong, J. S. Principles of Forecasting. Norwell, MA: Kluwer Academic Publishers.
- Ameco. (2017). 7 - GROSS DOMESTIC PRODUCT (INCOME APPROACH), LABOUR COSTS, 7.4 - NOMINAL COMPENSATION PER EMPLOYEE, TOTAL ECONOMY. Viitattu 29.10.2017 [http://ec.europa.eu/economy\\_finance/ameco/user/serie/SelectSerie.cfm](http://ec.europa.eu/economy_finance/ameco/user/serie/SelectSerie.cfm)
- Bank of England Statistical Interactive Database | Interest & Exchange Rates. (2017). Viitattu 29.10.2017, <http://www.bankofengland.co.uk/boeapps/iadb/index.asp?Travel=NixIRx&levels=1&C=C6D&C=DKY&C=DL1&C=DL4&C=DLC&C=DLI&C=DLN&C=DPU&C=DPW&C=E0T&C=E1E&C=11W&C=IPM&C=IPN&C=NTA&Z0Xtop.x=43&Z0Xtop.y=7&Nodes=X3790X3791X3873X33940X76573X3918X34234X34235X3887X3883X3874>
- Beldjazia, A., & Alatou, D. (2016). Precipitation variability on the massif Forest of Mahouna (North Eastern-Algeria) from 1986 to 2010. *International Journal of Management Sciences and Business Research ISSN*, 5(3), 2226–8235.
- Berg-Andersson, B., Kaitila, V., & Kaseva, H. (2017). Bkt kasvaa lähivuosina lähes samaa tahtia kuin viime vuonna. Viitattu 29.10.2017, <https://www.suhdanne.fi/kotimainen-talous/tuotanto-ja-tyollisyys/tuotanto/bkt-kasvaa-lahivuosina-lahes-samaa-tahtia-kuin-viime-vuonna/>
- Box, G. . E. . P., & Pierce, D. A. . (1970). Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models. *American Statistical Association*, 65(3)
- Cantore, C., León-ledesma, M. A., Mcadam, P., Cantore, C., León-ledesma, M. A., & Mcadam, P. (2010). *Shocking Stuff: Technology, Hours, and Factor Substitution*, European Central Bank Working Paper Series, (No. 1278).
- Chow, G. C., & Lin, A.-L. (1971). Best Linear Unbiased Interpolation, Distribution, and Extrapolation of Time Series By Related Series. *The Review of Economics and Statistics* .

- Clements, M. P., & Hendry, D. F. (1995). Forecasting in Cointegrated Systems. *Journal of Applied Econometrics*, 10(2), 127–146.
- Denton, F. T. (1971). Adjustment of monthly or quarterly series to annual totals: An approach based on quadratic minimization. *Journal of the American Statistical Association*, 66(333), 99–102.
- Dickey, D. A. ., & Fuller, W. A. . (1981). Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root Author The Econometric Society. *The Econometric Society*, 49(4), 1057–1072.
- Dovern, J., & Weisser, J. (2011). Accuracy, unbiasedness and efficiency of professional macroeconomic forecasts: An empirical comparison for the G7. *International Journal of Forecasting*, 27(2), 452–465.
- Etla: Historia: perustiedon tuottajasta laaja-alaiseksi tutkimuslaitokseksi. Viitattu 16.2.2018  
<https://www.etla.fi/tietoa-etlasta/historia/>
- Euro/ECU exchange rates - quarterly data. (2017). Viitattu 27.10.2017,  
[http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=ert\\_bil\\_eur\\_q&lang=en](http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=ert_bil_eur_q&lang=en)
- Euro ja Talous (2015). Suomen ulkomaankaupan lyhyt historia. *Euro Ja Talous*, 2015(5), 43–50.
- Evans, J. D. (1996). *Straightforward statistics for the behavioral sciences*. Pacific Grove, CA: Brooks/Cole Publishing.
- Fiacco, A. V. (1983). *Introduction to Sensitivity and Stability Analysis in Nonlinear Programming*. Academic Press, New York.
- Finanssiala. (2017). Suomea koskevat uusimmat talousennusteet. Viitattu 28.11.2017,  
<http://www.finanssiala.fi/tilastot/FK-tilasto-talousennusteet.pdf>
- Former euro area national currencies vs. euro/ECU - quarterly data. (2016). Viitattu 29.11.2017,  
[http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=ert\\_h\\_eur\\_q&lang=en](http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=ert_h_eur_q&lang=en)
- Gardner, R. H., O’Neill, R. V., Mankin, J. B., & Carney, J. H. (1981). A comparison of sensitivity analysis and error analysis based on a stream ecosystem model. *Ecological Modelling*.
- Granger, C. W. J. (1969). Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica*, 37(3), 424–438.
- Griffiths, W. E., Hill, R. C., & Judge, G. G. (1993). *Learning and Practicing Econometrics*. Wiley.
- Gujarati, D. N., & Porter, D. C. (2009). *Basic econometrics* (5th ed.). Boston: McGraw-Hill.



- Haavio, M., Kortelainen, M., & Kontulainen, J. (2009). Talouskriisi , finanssikriisi ja ennustaminen. *Kansantaloudellinen Aikakauskirja*, 105. vsk.(3), 324–330.
- Hamby, D. M. (1994). A review of techniques for parameter sensitivity analysis of environmental models. *Environmental Monitoring and Assessment*, 32(2), 135–154.
- Hamby, D. (1995). A comparison of sensitivity analysis techniques. *Health Physics*, 68(2), 195–204.
- Harvey, D., Leybourne, S. ja Newbold, P. (1997) Testing the Equality of Prediction Mean Squared Errors, *International Journal of Forecasting*, 13, 281–291.
- Hendry, D. F. (1996). A Theory of Co-Breaking. In *17th International Symposium of Forecasting*. Barbados, W.I., June 19-21, 1997.
- Henriksson, S., Ilmakunnas, S., Kangasniemi, M., Kotamäki, M., Lehmus, M., Lehto, E., & Taimio, H. (2012). Euroopan velkakriisi hidastaa kasvua. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-4-9-2012/>
- Hjelm, G., Bornevall, H., Fromlet, P., Nilsson, J., Stockhammar, P., & Wiberg, M. (2015). *Working paper. National Institute of Economic Research*. <https://doi.org/10.2139/ssrn.2182588>
- Hoffman, F.O.; Gardner, R.H. (1983). *Evaluation of uncertainties in environmental radiological assessment models*. Teoksessa: Till, J.E.; Meyer, H.R. eds. *Radiological assessments: a textbook on environmental dose assessment*. Washington, DC: U.S. Nuclear Regulatory Commission; Report No. NUREG/CR-3332; 1983
- Honkatukia, J., Tamminen, S., & Ahokas, J. (2014). Suomi on jo palvelutalous. *VATT Policy Brief*, 1, 1–12.
- Huovari, J., Lahtinen, M., Mäki-Fränti, P., & Volk, R. (2009). Talouskriisien ennustaminen vaikeaa. *Kansantaloudellinen Aikakauskirja*, 105. vsk.(3), 331–334.
- Husa, T., Ilmakunnas, S., Kangasniemi, M., Lehmus, M., Lehto, E., & Taimio, H. (2013). Vienti virkoaa ja taantuma taipuu Euroopan investointien vilkastuessa. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-17-9-2013/>
- Ilmakunnas, S., Kangasniemi, M., Lahtinen, J., Lehto, E., & Taimio, H. (2011a). Suomen talous toipuu – julkinen talous selvästi ylijäämäiseksi jo ensi vuonna. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-29-3-2011/>

- Ilmakunnas, S., Kangasniemi, M., Kotamäki, M., Lehmus, M., Lehto, E., Taimio, H., & Hovi, M. (2011b). Suomenkin kansantalous taipuu – kokonaistuotannon kasvu hidastuu tuntuvasti. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-30-8-2011/>
- Ilmakunnas, S., Kangasniemi, M., Lehmus, M., Lehto, E., & Taimio, H. (2012). Kasvun hitain vaihe on ohi. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-3-4-2012/>
- Ilmakunnas, S., Kangasniemi, M., Lehmus, M., Lehto, E., & Taimio, H. (2013). Suomen talouskasvu jää tänä vuonna 0,6 prosenttiin – ensi vuonna jo parempaa. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-18-3-2013/>
- Ilmakunnas, S., Kangasniemi, M., Kanninen, O., Lehmus, M., Lehto, E., & Taimio, H. (2014a). Euroopassa vihdoinkin käänne ylöspäin. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-20-3-2014/>
- Ilmakunnas, S., Kangasniemi, M., Keränen, H., Lehmus, M., Lehto, E., Lähdemäki, S., & Taimio, H. (2014b). Ukrainan kriisi taittoi Suomen talouskasvun. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-17-9-2014/>
- Ilmakunnas, S., Kangasniemi, M., Lehto, E., Lähdemäki, S., & Taimio, H. (2015). Suomen julkisen talouden alijäämä alle kolmeen prosenttiin ilman uusia menoleikkauksia. Viitattu 28.11.2017, <http://www.labour.fi/ennusteet/talousennuste-25-3-2015/>
- Inflation (CPI). (2017). Viitattu 28.6.2017, <https://data.oecd.org/price/inflation-cpi.htm>
- Isiklar, G., & Lahiri, K. (2007). How far ahead can we forecast? Evidence from cross-country surveys. *International Journal of Forecasting*, 23, 167–187.
- Judge, G. G., Griffiths, W. E., Hill, R. C., Lütkepohl, H., & Lee, T. C. (1985). *The Theory and practice of econometrics* (2nd ed.). New York: John Wiley.
- Kahnemann, & Tversky. (1979). Prospect Theory: an Analysis of Decision Under Risk, 47(2), 263–291.
- Kangasniemi, J. (2017). Viikon kysymys: Miksi talousennusteita tehdään? | Elinkeinoelämän keskusliitto. Viitattu 21.5.2018 <https://ek.fi/ajankohtaista/uutiset/2017/01/11/viikon-kysymys-miksi-talousennusteita-tehdään/>
- Keskisuomalainen (2008). Talousennustajia ja ennusteita. Viitattu 16.2.2018, <https://www.ksml.fi/paakirjoitus/Talousennustajia-ja-ennusteita/64219>

- Kontulainen, J. (2017). Blogi: Talousennusteista ja niiden laadinnasta. Viitattu 28.11.2017  
<https://www.eurojatalous.fi/fi/blogit/2017/talousennusteista-ja-niiden-laadinnasta/>
- Korhonen, M. (2018). *Suomen kansantalouden VAR-malli lyhyen aikavälin ennustamiseen* (Työpapereita 319). Palkansaajien tutkimuslaitos. Viitattu 20.5.2018  
<http://www.labour.fi/tutkimusjulkaisut/tyopapereita/tyopapereita-319/>
- Kotilainen, M. (2017a). Etlan ennustevirheet 1/2017. *Etla Suhdannejulkaisu 1/2017*. Viitattu 27.10.2017, <https://www.suhdanne.fi/kotimainen-talous/ennustevirheet/etlan-ennustevirheet-12017/>
- Kotilainen, M. (2017b). Katsaus suhdannekehitykseen 1/2017. *Etla Suhdannejulkaisu 1/2017*. Viitattu 27.10.2017, <https://www.suhdanne.fi/tiivistelma/katsaus-suhdannekehitykseen-2/>
- Lanne, M. (2009). Ennustajien tappiofunktiot ja BKT-ennusteiden rationaalisuus. *Kansantaloudellinen Aikakauskirja*, 105(4), 416–421.
- Lehmus, M. (2007). Empirical Macroeconomic Model of the Finnish Economy (EMMA). *Labour Institute for Economic Research Discussion Papers*.
- Lehmus, M. (2009). Empirical Macroeconomic Model of the Finnish Economy (EMMA). *Economic Modelling*, 26(5), 926–933.
- Lehto, E. (2009). Käsitteitä Suomen kansantalouden suhdanneherkkyydestä ja suhdanteiden ennustettavuudesta globaalissa taloudessa. *Kansantaloudellinen Aikakauskirja*, 105. vsk.(3), 341–346.
- Lehto, E., Lähdemäki, S., & Kiema, I. (2015). *Teollisuuden, rakentamisen ja liike-elämän palveluiden näkymät syksyllä 2015*.
- Lin, W. (1997). Impulse Response Volatility in GARCH Conditional Models. *Journal of Business & Economic Statistics*, 15(1), 15–25.
- Loungani, P. (2001). How accurate are private sector forecasts? Cross-country evidence from Consensus forecasting of output growth. *International Journal of Forecasting*, 17(3), 419–432.
- Lütkepohl, H. (2005): *New Introduction to Multiple Time Series Analysis*, Springer.
- Lütkepohl, H., & Krätzig, M. (2004). *Applied Time Series Econometrics*. Cambridge University Press.
- Malkiel, B. G. (2003). The Efficient Market Hypothesis and Its Critics. *Journal of Economic*

*Perspective*, 17(1), 59–82. <https://doi.org/10.1257/089533003321164958>

Mayer, T. (1975). Selecting Economic Hypotheses by Goodness of Fit. *The Economic Journal*, 85(340), 877–883.

Mannermaa, K. (1975). Kansantalouden ennustamis- ja suunnittelusysteemi “KESSU.” *Kansantaloudellinen Aikakauskirja*, 71. vsk.(3), 282–293.

Mikó, P., Löschenberger, F., Hiltbrunner, J., Aebi, R., Megyeri, M., Kovács, G., ... Rakszegi, M. (2014). Comparison of bread wheat varieties with different breeding origin under organic and low input management. *Euphytica*, 199(1–2), 69–80.

Monthly Monetary and Financial Statistics (MEI) : Exchange rates (USD monthly averages). (2017). Viitattu 27.10.2017, <http://stats.oecd.org/index.aspx?queryid=169>

Nominal unit labour cost (NULC) - quarterly data - Eurostat. (2017). Viitattu 27.10.2017, <http://ec.europa.eu/eurostat/web/products-datasets/-/tipslm40>

Nordean talousennuste: Suomen talouskasvu kiihtyy 3 prosenttiin. (2017). Viitattu 27.10.2017, <https://www.nordea.com/fi/media/uutiset-ja-lehdistotiedotteet/press-releases/2017/06-12-10h03-nordean-talousennuste-suomen-talouskasvu-kiihtyy-3-prosenttiin.html>

Pannell, D. J. (1997). Sensitivity analysis of normative economic models: theoretical framework and practical strategies. *Agricultural Economics*, 16(2), 139–152.

Pecican, Eugen St., 2010. Forecasting Based On Open Var Model. *Journal for Economic Forecasting*, Institute for Economic Forecasting, vol. 13(1), pages 59-69, March. <https://ideas.repec.org/a/rjr/romjef/vy2010i1p59-69.html>

Pehkonen, J. (2002). Talousennusteiden osuvuus 1997-2001: valistuneita arvauksia. *Kansantaloudellinen Aikakauskirja*, 98. vsk.(2), 115–136.

Quarterly national Accounts: Gross domestic product – expenditure approach, VPVOBARSA: US dollars, volume estimates, fixed PPPs, OECD reference year, annual levels, seasonally adjusted. (2017). Viitattu 29.11.2017, <https://stats.oecd.org/index.aspx?queryid=350>

Robertson, J. C., & Tallman, E. W. (1999). Vector Autoregressions: Forecasting and Reality. *Economic Review*, 84(1), 4–18.

Rossana, R. J., & Seater, J. J. (1995). Temporal Aggregation and Economic Time Series. *Journal of*

*Business & Economic Statistics*, 13(4), 441–451.

Sims, C. A. (1980). Macroeconomics and Reality. *Econometrica*, 48 (1), 1-48.

Suomen Pankki. (2017). Euribor-korot. Viitattu 28.11.2017,  
[https://www.suomenpankki.fi/fi/Tilastot/korot/taulukot2/korot\\_taulukot/euribor\\_korot\\_short\\_fi/](https://www.suomenpankki.fi/fi/Tilastot/korot/taulukot2/korot_taulukot/euribor_korot_short_fi/)

Suomen Pankki. (2017). Euribor-korot ja Eonia-korko, kuukauden keskiarvo. Viitattu 28.11.2017,  
[https://www.suomenpankki.fi/fi/Tilastot/korot/taulukot2/korot\\_taulukot/euribor\\_korot\\_long\\_fi/](https://www.suomenpankki.fi/fi/Tilastot/korot/taulukot2/korot_taulukot/euribor_korot_long_fi/)

The Central Bank of the Russian Federation. Доллар США (Neuvostoruplan dollarikurssi). Viitattu 28.11.2017, [http://cbr.ru/currency\\_base/OldDataFiles/USD.xls](http://cbr.ru/currency_base/OldDataFiles/USD.xls)

Tilastokeskus (2017). 001 Väestö työmarkkina-aseman, sukupuolen ja iän mukaan. Viitattu 28.11.2017,  
[http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin\\_\\_tym\\_\\_tyti/statfin\\_tyti\\_pxt\\_001.px/?rxid=9e6e9b95-00bc-47fc-9332-d6fced114121](http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin__tym__tyti/statfin_tyti_pxt_001.px/?rxid=9e6e9b95-00bc-47fc-9332-d6fced114121)

Tilastokeskus (2017). 001 Bruttokansantuote ja -tulo käypiin hintoihin 1975-2016. Viitattu 28.11.2017,  
[http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin\\_\\_kan\\_\\_vtp/statfin\\_vtp\\_pxt\\_001.px/?rxid=af50fe4a-6f78-44bd-a226-8a5d91f53296](http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin__kan__vtp/statfin_vtp_pxt_001.px/?rxid=af50fe4a-6f78-44bd-a226-8a5d91f53296)

Tilastokeskus (2017). 001 Kuluttajahintaindeksi 1990=100. Viitattu 28.6.2017,  
[http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin\\_\\_hin\\_\\_khi/030\\_khi\\_tau\\_103.px/?rxid=67c10ad8-c967-497d-bb96-9c406537aad9](http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin__hin__khi/030_khi_tau_103.px/?rxid=67c10ad8-c967-497d-bb96-9c406537aad9)

Tilastokeskus (2017). 007 - Tuotanto- ja tulonmuodostustilit 1975-2016. Viitattu 29.11.2017,  
[http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin\\_\\_kan\\_\\_vtp/statfin\\_vtp\\_pxt\\_007.px/?rxid=af50fe4a-6f78-44bd-a226-8a5d91f53296](http://pxnet2.stat.fi/PXWeb/pxweb/fi/StatFin/StatFin__kan__vtp/statfin_vtp_pxt_007.px/?rxid=af50fe4a-6f78-44bd-a226-8a5d91f53296)

Tulli. (2005). Kauppavaihto (maat suuruusjärjestyksessä). Viitattu 28.11.2017,  
[http://tulli.fi/documents/2912305/3604174/Kauppavaihto \(maat suuruusjärjestyksessä\) - Handelsomsättning \(länder i storleksordning\) - Trade \(countries according to magnitude\) 2005/61b73e73-5e49-4595-ae53-67a1fa24bc84?version=1.2](http://tulli.fi/documents/2912305/3604174/Kauppavaihto+(maat+suuruusjarjestyksessa)-Handelsomsattning+(lander+i+storleksordning)-Trade+(countries+according+to+magnitude)2005/61b73e73-5e49-4595-ae53-67a1fa24bc84?version=1.2)

Tulli. (2010). Kauppavaihto (maat suuruusjärjestyksessä). Viitattu 28.11.2017,  
[http://tulli.fi/documents/2912305/3604174/Kauppavaihto \(maat suuruusjärjestyksessä\) - Handelsomsättning \(länder i storleksordning\) - Trade \(countries according to magnitude\)](http://tulli.fi/documents/2912305/3604174/Kauppavaihto+(maat+suuruusjarjestyksessa)-Handelsomsattning+(lander+i+storleksordning)-Trade+(countries+according+to+magnitude))

2010/04cd125e-950f-4868-b8b9-dd3f49f5c7c9?version=1.1

Tulli. (2015). Kauppavaihto (maat suuruusjärjestyksessä). Viitattu 28.11.2017,  
[http://tulli.fi/documents/2912305/3365775/Kauppavaihto \(maat suuruusjärjestyksessä\) - Handelsomsättning \(länder i storleksordning\) - Trade \(countries according to magnitude\) 2015/4395a6d3-f2d4-4f58-bf41-9ed9f8244f26?version=1.1](http://tulli.fi/documents/2912305/3365775/Kauppavaihto+(maat+suuruusjarjestyksessa)+-+Handelsomsattning+(lander+i+storleksordning)+-+Trade+(countries+according+to+magnitude)+2015/4395a6d3-f2d4-4f58-bf41-9ed9f8244f26?version=1.1)

Unit labour cost - quarterly data - Eurostat. (2014). Viitattu 28.11.2017,  
[http://ec.europa.eu/eurostat/web/products-datasets/-/namq\\_aux\\_ulc](http://ec.europa.eu/eurostat/web/products-datasets/-/namq_aux_ulc)

Valtiovarainministeriö. (2016). Katsaus valtion taloudellisiin vastuisiin ja riskeihin 2016. *Valtiovarainministeriön Julkaisu, 15a.*

Valtiovarainministeriö. (2017). Taloudellinen katsaus Kevät 2015. *Valtiovarainministeriön Julkaisu, 17a*

Vartiainen, J. (2014). Talousennusteet ja yhteiskunnan päätöksentekokyky. *Kansantaloudellinen Aikakauskirja, 110. vsk.(2)*, 251–265.

Wiio, O. A. (1970). Ennustamisesta ennusteisiin. *Kansantaloudellinen Aikakauskirja, 66. vsk.(1)*, 15–30.

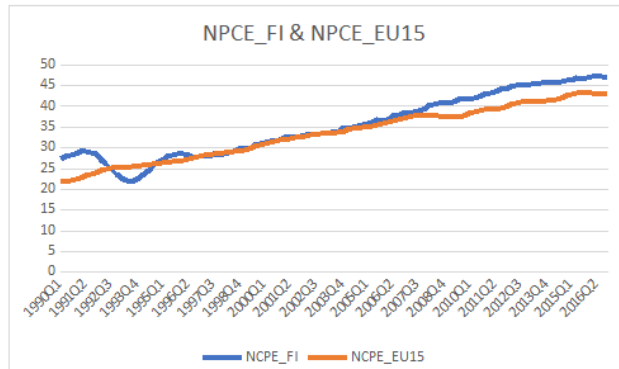
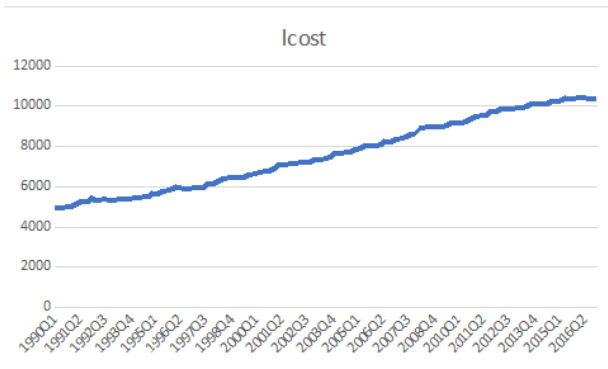
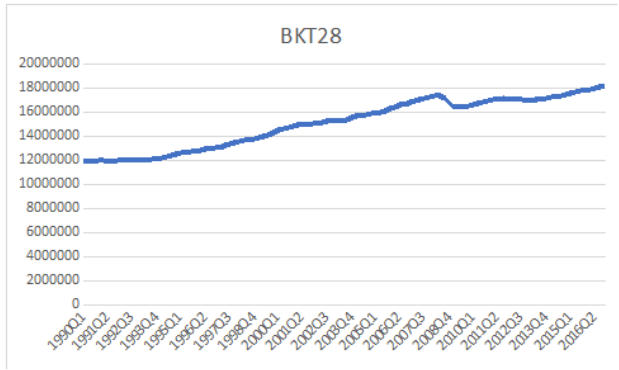
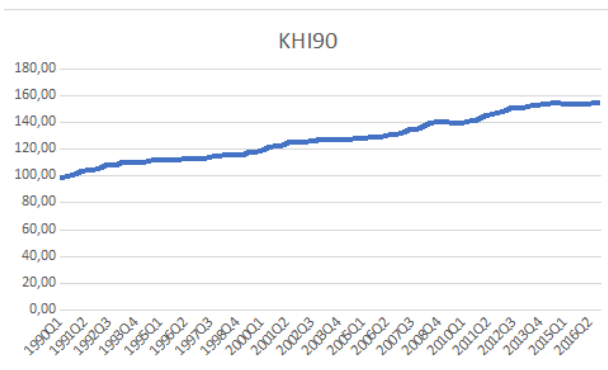
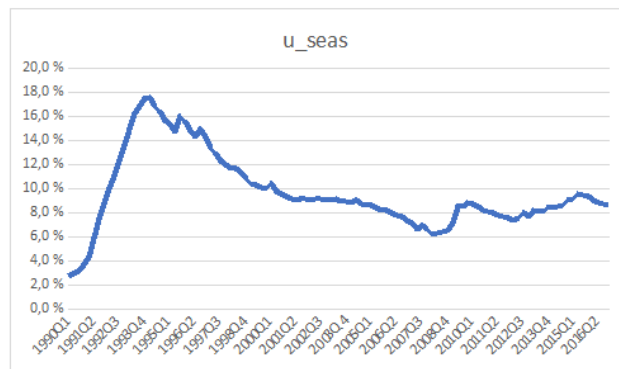


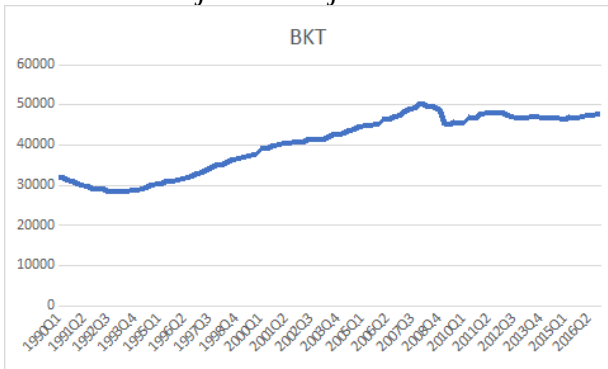
World Development Indicators | DataBank. (2017). Viitattu 29.11.2017,  
<http://databank.worldbank.org/data/reports.aspx?source=2&series=NY.GDP.MKTP.CD&country>

# LIITTEET

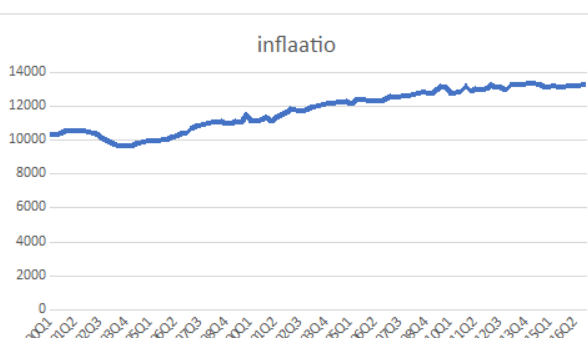
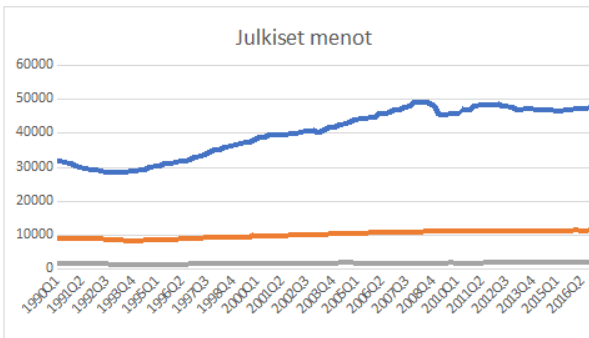
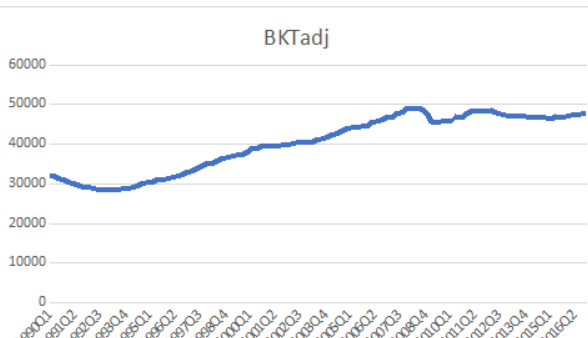
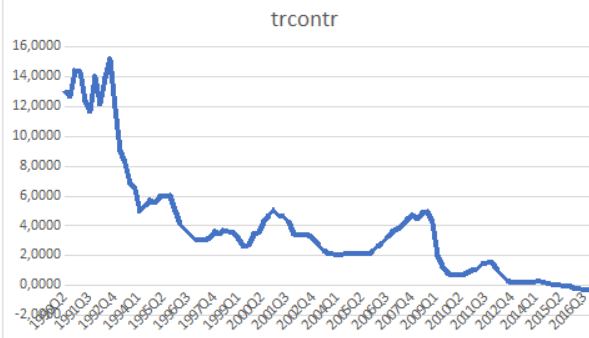


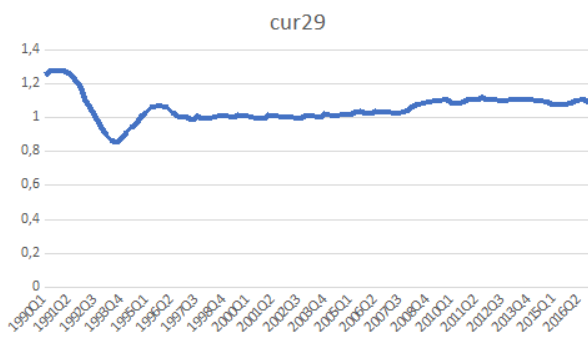
## Liite 1: Muuttuja-analyysi

Muuttuja	Muuttujan selite	Arvostus	Kausitasoitus	Muuttujan muoto mallissa	Lähde
bkt	Bruttokansantuote	viitevuoden hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskus
bktadj	Korjattu bruttokansantuote	viitevuoden hintoihin	Kausitasoitettu: alkuperäisen kausitasoitettun BKT-sarjan erotuksena on otettu neljännesvuosille tasan jaettu vuosikohtainen vlimääräinen	Logaritmin 1. differenssi	Tilastokeskus, PT:n toimialaennuste 2015-2017
c	Yksityinen kulutus	viitevuoden hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskus
i	Yksityiset investoinnit	viitevuoden hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskus
u_seas	Työttömyysaste	-	Kausitasoitettu	taso	Tilastokeskus
khi90	Kuluttajahintaindeksi	-	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskus
bkt28	EU-maiden bruttokansantuote	viitevuoden hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Kvartaaliaineisto 1995-2016 OECD:lta, vuositason aineisto 1990-1995 Worldbankista hajotettu noudattaen OECD:n EU15:n BKT:n kasvuasteita 1990-1995
lcost	Työvoimakustannukset työntekijää kohti	käypiin hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskukselta kahdesta lähteestä yhdistelty. Puuttuvat vuodet 2015-2016 saatu Amecon nimellisten kompensatioiden sarjan kasvuasteista
ncpe_fi	Nimellinen kompensatio työntekijää kohti Suomessa	käypiin hintoihin	Kausitasoitettu: Jaettu vuosiaineistosta lcost-sarjan referenssin perusteella neljännesvuosiin		Amecon vuosiaineisto, joka on hajotettu lcost-sarjan perusteella
ncpe_eu15	Nimellinen kompensatio työntekijää kohti EU15:ssä	käypiin hintoihin	Jaettu vuosiaineistosta tasan neljännesvuosiin		Amecon vuosiaineisto, joka on hajotettu tasan neljännesvuosille
fi_eu15	Suomen ja EU15:n nimellisten kompensatioiden suhde	käypiin hintoihin		taso (logaritmoitu tai alkuperäinen)	
cur29	Valuuttakori		Ei	Logaritmin 1. differenssi	Valuuttakurssitiedot Eurostatilta, OECD:lta, Venäjän keskus-pankilta sekä Bank of Englandilta. Painot tullin
bkt29	Vientikori		Ei	Logaritmin 1. differenssi	Painot tullin arkistoista
r	Kolmen kuukauden korko		Ei	taso	Suomen Pankki
trcontr	Ulkomaankaupan kontribuutio		Kausitasoitettu	taso	Laskettu Tilastokeskuksen tuonnin, viennin ja BKT:n aikasarjoista
gc	Julkisen kulutus	viitevuoden hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskus
gi	Julkiset investoinnit	viitevuoden hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskus
g	Julkiset menot	viitevuoden hintoihin	Kausitasoitettu	Logaritmin 1. differenssi	Tilastokeskus
inf	Inflaatio		Ei	taso	OECD

Liite 2: Muuttujien kuvaajat







Liite 3: Yksikköjuuritestien tulokset

<u>Yksikköjuuritesti</u>	Tasomuuttuja		Differenssimuuttuja	
	p-arvo	Stationaarisuus	p-arvo	Stationaarisuus
bkt	0,64	Epästationaarinen	<0,01	Stationaarinen
bktadj	0,89	Epästationaarinen	<0,01	Stationaarinen
c	0,99	Epästationaarinen	<0,01	Stationaarinen
i	0,66	Epästationaarinen	<0,01	Stationaarinen
u_seas	0,00	Stationaarinen		
khi90	0,95	Epästationaarinen	<0,01	Stationaarinen
bkt28	0,88	Epästationaarinen	<0,01	Stationaarinen
lcost	0,56	Epästationaarinen	<0,01	Stationaarinen
ncpe_fi	0,91	Epästationaarinen	<0,01	Stationaarinen
ncpe_eu15	0,93	Epästationaarinen	<0,01	Stationaarinen
fi_eu15	<0,01	Stationaarinen		
cur29	0,78	Epästationaarinen	<0,01	Stationaarinen
bkt29	0,98	Epästationaarinen	<0,01	Stationaarinen
r	<0,01	Stationaarinen		
trcontr	<0,01	Stationaarinen		
gc	0,85	Epästationaarinen	<0,01	Stationaarinen
gi	0,01	Stationaarinen		
g	0,58	Epästationaarinen	<0,01	Stationaarinen
inf	0,05	Stationaarinen		

#### Liite 4: Muuttujien ristikkäiskorrelaatiot

##### Muuttujien ristikkäiskorrelaatiot 1990-2016

	dbkt	dbktadj	dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfe_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf
dbkt	1	0,96	0,46	0,49	0,34	-0,49	0,01	0,72	0,11	-0,45	0,19	0,00	0,68	-0,26	0,07	0,10	0,07	0,21	0,16	-0,33
dbktadj	0,96	1	0,47	0,48	0,34	-0,53	0,02	0,68	0,11	-0,46	0,22	0,01	0,65	-0,28	0,05	0,11	0,09	0,20	0,18	-0,35
dc	0,46	0,47	1	0,51	0,16	-0,40	-0,17	0,40	0,10	-0,24	0,31	0,25	0,47	-0,30	0,07	0,09	0,12	0,19	0,20	-0,29
di	0,49	0,48	0,51	1	0,29	-0,56	-0,17	0,47	-0,11	-0,36	0,20	0,16	0,58	-0,39	0,14	0,05	0,14	-0,11	0,03	-0,37
u_seas	0,34	0,34	0,16	0,29	1	-0,17	-0,27	0,24	-0,06	-0,70	-0,01	0,06	0,11	0,07	-0,04	0,12	-0,06	0,02	-0,03	-0,41
du_seas	-0,49	-0,53	-0,40	-0,56	-0,17	1	0,10	-0,38	-0,05	0,45	-0,45	-0,23	-0,50	0,61	-0,13	0,11	-0,16	-0,09	-0,17	0,40
dkhi90	0,01	0,02	-0,17	-0,17	-0,27	0,10	1	0,06	0,14	0,22	-0,09	-0,30	0,02	0,35	-0,02	-0,06	0,00	0,03	0,02	0,62
dbkt28	0,72	0,68	0,40	0,47	0,24	-0,38	0,06	1	0,12	-0,27	0,13	0,02	0,80	-0,13	0,15	0,07	0,06	0,13	0,12	-0,31
dlcost	0,11	0,11	0,10	-0,11	-0,06	-0,05	0,14	0,12	1	0,10	0,52	0,10	0,15	0,11	-0,08	0,07	0,04	0,13	0,11	0,15
fi_eu15	-0,45	-0,46	-0,24	-0,36	-0,70	0,45	0,22	-0,27	0,10	1	0,00	-0,06	-0,27	0,17	0,04	-0,08	0,04	0,04	0,05	0,40
dfe_eu15	0,19	0,22	0,31	0,20	-0,01	-0,45	-0,09	0,13	0,52	0,00	1	0,58	0,26	-0,37	0,05	-0,05	0,27	0,16	0,29	-0,13
dcur29	0,00	0,01	0,25	0,16	0,06	-0,23	-0,30	0,02	0,10	-0,06	0,58	1	0,07	-0,19	0,21	-0,10	0,08	0,04	0,09	-0,14
dbkt29	0,68	0,65	0,47	0,58	0,11	-0,50	0,02	0,80	0,15	-0,27	0,26	0,07	1	-0,41	0,13	0,08	0,15	0,11	0,17	-0,38
r	-0,26	-0,28	-0,30	-0,39	0,07	0,61	0,35	-0,13	0,11	0,17	-0,37	-0,19	-0,41	1	-0,09	0,10	-0,12	-0,10	-0,14	0,64
dr	0,07	0,05	0,07	0,14	-0,04	-0,13	-0,02	0,15	-0,08	0,04	0,05	0,21	0,13	-0,09	1	-0,14	0,03	-0,04	0,00	-0,13
trcontr	0,10	0,11	0,09	0,05	0,12	0,11	-0,06	0,07	0,07	-0,08	-0,05	-0,10	0,08	0,10	-0,14	1	-0,07	0,19	0,07	0,00
dgc	0,07	0,09	0,12	0,14	-0,06	-0,16	0,00	0,06	0,04	0,04	0,27	0,08	0,15	-0,12	0,03	-0,07	1	0,13	0,81	-0,02
dgi	0,21	0,20	0,19	-0,11	0,02	-0,09	0,03	0,13	0,13	0,04	0,16	0,04	0,11	-0,10	-0,04	0,19	0,13	1	0,68	-0,10
dg	0,16	0,18	0,20	0,03	-0,03	-0,17	0,02	0,12	0,11	0,05	0,29	0,09	0,17	-0,14	0,00	0,07	0,81	0,68	1	-0,07
inf	-0,33	-0,35	-0,29	-0,37	-0,41	0,40	0,62	-0,31	0,15	0,40	-0,13	-0,14	-0,38	0,64	-0,13	0,00	-0,02	-0,10	-0,07	1

*Liite 5: Muuttujien viiveiden korrelaatiot BKT:n ja korjatun BKT:n kanssa*  
**Muuttujien  $y_t$  viiveiden korrelaatiot dBKT:n kanssa**

dbkt <sub>t</sub> , dy <sub>i,t</sub>																			
dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dg_c	dg_i	dg	infl		
1992-2016	0,41	0,38	0,23	-0,39	0,15	0,74	0,23	-0,28	0,17	-0,05	0,66	-0,01	0,07	0,13	0,08	0,22	0,18	-0,16	
1992-2007	0,33	0,33	-0,02	-0,43	0,01	0,48	0,18	0,08	0,37	0,17	0,39	-0,43	0,18	-0,02	0,13	0,02	0,11	-0,16	
2008-2016	0,43	0,38	0,38	-0,34	0,30	0,82	0,27	0,02	-0,01	-0,45	0,80	-0,26	0,13	0,24	-0,08	0,40	0,25	-0,16	
2012-2016	0,49	0,15	0,49	-0,13	-0,28	0,52	0,17	-0,18	0,47	-0,14	0,28	-0,47	0,07	0,21	0,49	0,13	0,40	-0,54	

dbkt <sub>t</sub> , dy <sub>i,t-1</sub>																			
dc	di	u_seas	du_seas	dkhi90	dbkt28	dt yövoimafi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dg_c	dg_i	dg	infl			
1992-2016	0,22	0,42	0,29	-0,25	-0,05	0,53	0,04	-0,33	0,09	0,07	0,57	-0,07	0,10	0,05	0,29	0,00	0,21	-0,37	
1992-2007	0,22	0,38	0,05	-0,43	-0,09	0,29	0,03	-0,09	0,33	0,15	0,46	-0,43	0,27	0,09	0,50	0,19	0,48	-0,28	
2008-2016	0,14	0,45	0,49	-0,04	-0,04	0,54	-0,08	0,02	-0,29	-0,01	0,59	-0,46	0,17	-0,09	-0,01	-0,10	-0,10	-0,46	
2012-2016	-0,11	0,54	0,50	-0,19	-0,47	0,39	-0,39	-0,46	-0,02	0,30	-0,16	-0,46	0,42	-0,34	0,05	-0,12	-0,03	-0,58	

dbkt <sub>t</sub> , dy <sub>i,t-2</sub>																			
dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf		
1992-2016	0,31	0,21	0,34	-0,22	-0,21	0,38	0,14	-0,34	0,13	0,10	0,39	-0,11	-0,02	0,13	-0,07	0,04	-0,03	-0,45	
1992-2007	0,31	0,27	0,13	-0,40	-0,18	0,30	0,16	-0,22	0,37	0,17	0,49	-0,46	-0,12	-0,06	-0,01	0,08	0,03	-0,37	
2008-2016	0,25	0,01	0,50	-0,01	-0,29	0,25	0,04	0,14	-0,14	0,08	0,22	-0,52	0,04	0,27	-0,29	0,01	-0,16	-0,55	
2012-2016	0,15	-0,05	0,56	0,23	-0,36	0,29	0,02	-0,42	0,22	0,32	0,29	-0,56	0,22	0,37	-0,27	-0,09	-0,23	-0,47	

dbkt <sub>t</sub> , dy <sub>i,t-3</sub>																			
dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf		
1992-2016	0,17	0,16	0,37	-0,18	-0,24	0,24	-0,07	-0,36	0,01	-0,06	0,20	-0,08	-0,09	-0,04	0,14	0,12	0,16	-0,41	
1992-2007	0,20	0,22	0,20	-0,39	-0,06	0,15	-0,10	-0,33	0,22	0,07	0,29	-0,42	-0,10	-0,03	0,25	0,32	0,34	-0,35	
2008-2016	0,03	-0,03	0,48	0,05	-0,43	0,10	-0,20	0,18	-0,32	-0,24	0,02	-0,46	-0,06	-0,14	-0,07	-0,01	-0,07	-0,49	
2012-2016	0,06	0,24	0,47	0,19	-0,37	0,27	-0,28	-0,56	-0,21	-0,13	-0,33	-0,57	-0,07	-0,06	0,15	-0,42	-0,13	-0,50	

dbkt <sub>t</sub> , dy <sub>i,t-4</sub>																			
dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf		
1992-2016	0,01	0,17	0,40	-0,04	-0,36	0,17	-0,17	-0,34	-0,05	0,00	0,17	-0,05	-0,03	0,07	0,01	-0,14	-0,07	-0,43	
1992-2007	0,26	0,32	0,27	-0,45	-0,25	0,30	-0,13	-0,37	0,15	0,10	0,36	-0,37	-0,04	0,02	0,02	-0,24	-0,10	-0,45	
2008-2016	-0,33	-0,09	0,47	0,60	-0,53	-0,11	-0,53	0,27	-0,51	-0,12	-0,07	-0,39	0,01	0,06	-0,07	-0,08	-0,11	-0,44	
2012-2016	-0,26	0,02	0,41	0,31	-0,43	0,37	-0,21	-0,43	-0,36	0,04	0,02	-0,51	0,12	0,08	-0,32	-0,21	-0,31	-0,48	

## Muuttujien $y_i$ viiveiden korrelaatiot dBKTadj:n kanssa

dbktadj <sub>t</sub> dy <sub>i,t</sub>																			
	dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf	
1992-2016		0,42	0,36	0,23	-0,43	0,17	0,70	0,24	-0,28	0,20	-0,05	0,61	-0,02	0,05	0,14	0,11	0,21	0,20	-0,16
1992-2007		0,28	0,27	0,01	-0,42	-0,02	0,43	0,13	0,06	0,35	0,16	0,37	-0,43	0,18	0,01	0,20	0,02	0,17	-0,25
2008-2016		0,52	0,38	0,28	-0,42	0,39	0,79	0,39	-0,05	0,12	-0,44	0,75	-0,17	0,11	0,24	-0,13	0,40	0,23	-0,10
2012-2016		0,59	0,20	0,37	-0,32	-0,14	0,47	0,24	-0,16	0,40	-0,24	0,22	-0,28	0,05	0,07	0,39	0,01	0,26	-0,42

dbktadj <sub>t</sub> dy <sub>i,t-1</sub>																			
	dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf	
1992-2016		0,22	0,44	0,30	-0,26	-0,05	0,50	0,05	-0,33	0,11	0,08	0,55	-0,07	0,11	0,04	0,30	0,01	0,23	-0,37
1992-2007		0,23	0,38	0,09	-0,40	-0,12	0,24	0,04	-0,10	0,33	0,16	0,42	-0,43	0,19	0,14	0,42	0,20	0,42	-0,35
2008-2016		0,12	0,49	0,43	-0,07	0,00	0,54	-0,06	-0,10	-0,27	-0,02	0,60	-0,35	0,20	-0,17	0,11	-0,10	-0,04	-0,42
2012-2016		-0,14	0,55	0,46	-0,10	-0,37	0,43	-0,44	-0,40	-0,13	0,19	-0,01	-0,23	0,42	-0,30	0,18	0,00	0,12	-0,49

dbktadj <sub>t</sub> dy <sub>i,t-2</sub>																			
	dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf	
1992-2016		0,32	0,24	0,34	-0,23	-0,22	0,37	0,16	-0,35	0,16	0,11	0,40	-0,10	-0,01	0,11	-0,06	0,05	-0,02	-0,45
1992-2007		0,32	0,26	0,17	-0,38	-0,19	0,28	0,16	-0,22	0,37	0,17	0,46	-0,45	-0,19	-0,14	0,01	0,10	0,05	-0,41
2008-2016		0,25	0,07	0,45	-0,02	-0,30	0,26	0,12	0,04	-0,08	0,08	0,25	-0,41	0,07	0,33	-0,32	0,02	-0,17	-0,52
2012-2016		0,03	0,03	0,49	0,02	-0,26	0,27	0,21	-0,30	0,34	0,35	0,39	-0,35	0,24	0,31	-0,37	0,05	-0,23	-0,40

dbktadj <sub>t</sub> dy <sub>i,t-3</sub>																			
	dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf	
1992-2016		0,22	0,20	0,38	-0,21	-0,26	0,24	-0,08	-0,38	0,02	-0,05	0,19	-0,08	-0,09	-0,03	0,17	0,13	0,19	-0,42
1992-2007		0,22	0,22	0,23	-0,35	-0,19	0,09	-0,14	-0,33	0,20	0,09	0,22	-0,40	-0,17	-0,01	0,27	0,33	0,36	-0,37
2008-2016		0,13	0,06	0,44	-0,05	-0,36	0,15	-0,17	0,06	-0,31	-0,26	0,06	-0,38	-0,05	-0,13	-0,03	0,00	-0,05	-0,49
2012-2016		0,44	0,32	0,47	0,05	-0,37	0,33	-0,17	-0,51	-0,09	-0,05	-0,22	-0,43	-0,01	-0,14	0,35	-0,30	0,07	-0,46

dbktadj <sub>t</sub> dy <sub>i,t-4</sub>																			
	dc	di	u_seas	du_seas	dkhi90	dbkt28	dlcost	fi_eu15	dfi_eu15	dcur29	dbkt29	r	dr	trcontr	dgc	dgi	dg	inf	
1992-2016		0,03	0,21	0,41	-0,07	-0,35	0,20	-0,16	-0,37	-0,04	0,03	0,18	-0,05	-0,02	0,05	0,03	-0,14	-0,06	-0,44
1992-2007		0,25	0,31	0,29	-0,44	-0,25	0,24	-0,10	-0,37	0,16	0,14	0,30	-0,34	-0,08	0,03	0,07	-0,16	-0,02	-0,45
2008-2016		-0,30	0,02	0,47	0,58	-0,50	-0,02	-0,54	0,16	-0,54	-0,13	-0,01	-0,33	0,02	0,03	-0,11	-0,12	-0,18	-0,45
2012-2016		-0,39	0,21	0,46	0,29	-0,40	0,51	-0,33	-0,45	-0,36	0,12	0,07	-0,46	0,14	-0,10	-0,48	-0,50	-0,57	-0,44

Liite 6: Korjatun BKT:n ennustevertailu fi\_eu15:n funktiomuotoa vaihdellen

**KUUDEN NELJÄNNESVUODEN ENNUSTEET (syksyn ennusteet)**

fi_eu15 endogeeninen	Korjatun BKT:n ennustevirheet (ennustettu kasvuaste (%) - toteutunut(%))						
	Malli 1	Malli 2	Malli 3	Malli 4	Malli 5	Malli 6	Malli 7
2010	0,137	0,025	0,152	0,040	0,132	0,147	0,121
2011	-1,320	-1,470	-1,121	-1,302	-1,246	-1,052	-0,552
2011	-0,208	-0,303	-0,196	-0,292	-0,239	-0,228	-0,162
2012	0,575	0,604	0,652	0,663	0,507	0,572	0,683
2012	0,159	0,152	0,174	0,166	0,122	0,135	0,163
2013	1,112	1,220	1,183	1,287	0,987	1,042	0,940
2013	0,038	0,042	0,042	0,046	-0,001	0,001	0,023
2014	1,308	1,280	1,342	1,312	1,220	1,242	1,283
2014	0,027	0,003	0,024	0,000	-0,028	-0,032	0,033
2015	0,208	0,207	0,174	0,171	0,086	0,040	0,156
2015	0,166	0,167	0,146	0,147	0,171	0,152	0,248
2016	-0,218	-0,264	-0,406	-0,441	-0,208	-0,385	-0,226
Neliösumma	5,229	5,911	5,192	5,876	4,441	4,329	3,505
Ennustevirheiden itseisarvojen keskiarvo	0,456	0,478	0,468	0,489	0,412	0,419	0,382

fi_eu15 eksogeeninen	Korjatun BKT:n ennustevirheet (ennustettu kasvuaste (%) - toteutunut(%))						
	Malli 1	Malli 2	Malli 3	Malli 4	Malli 5	Malli 6	Malli 7
2010	0,148	0,036	0,164	0,051	0,143	0,159	0,168
2011	-1,276	-1,543	-1,082	-1,413	-1,195	-1,008	-0,540
2011	-0,210	-0,311	-0,199	-0,302	-0,241	-0,231	-0,177
2012	0,428	0,359	0,449	0,343	0,335	0,343	0,629
2012	0,147	0,135	0,159	0,145	0,109	0,119	0,135
2013	0,810	0,886	0,771	0,846	0,645	0,590	0,589
2013	0,034	0,038	0,036	0,041	-0,006	-0,004	-0,024
2014	1,164	1,114	1,149	1,099	1,051	1,022	1,131
2014	0,025	-0,001	0,022	-0,004	-0,030	-0,034	0,006
2015	0,103	0,064	0,044	0,001	-0,047	-0,120	-0,020
2015	0,162	0,164	0,143	0,145	0,168	0,149	0,234
2016	-0,397	-0,475	-0,604	-0,665	-0,393	-0,585	-0,415
Neliösumma	4,106	4,910	3,768	4,618	3,335	3,001	2,621
Ennustevirheiden itseisarvojen keskiarvo	0,409	0,427	0,402	0,421	0,363	0,364	0,339

log(fi_eu15) eksogeeninen	Korjatun BKT:n ennustevirheet (ennustettu kasvuaste (%) - toteutunut(%))						
	Malli 1	Malli 2	Malli 3	Malli 4	Malli 5	Malli 6	Malli 7
2010	0,161	0,050	0,145	0,064	0,100	0,170	0,184
2011	-1,275	-1,568	-0,619	-1,455	-0,924	-1,028	-0,513
2011	-0,211	-0,316	-0,142	-0,310	-0,151	-0,236	-0,173
2012	0,407	0,332	0,667	0,285	0,595	0,283	0,604
2012	0,134	0,118	0,165	0,125	0,163	0,102	0,124
2013	0,767	0,851	0,666	0,777	0,654	0,500	0,511
2013	0,032	0,038	-0,007	0,038	0,070	-0,010	-0,034
2014	1,150	1,097	1,122	1,058	1,363	0,971	1,078
2014	0,019	-0,007	0,041	-0,013	0,049	-0,043	-0,006
2015	0,074	0,032	-0,014	-0,059	0,089	-0,187	-0,087
2015	0,160	0,164	0,225	0,141	0,138	0,142	0,226
2016	-0,417	-0,500	-0,436	-0,720	-0,525	-0,639	-0,452
Neliösumma	3,998	4,892	2,843	4,580	3,865	2,891	2,395
Ennustevirheiden itseisarvojen keskiarvo	0,401	0,423	0,354	0,420	0,402	0,359	0,333

## KAHDEKSAN NELJÄNNESVUODEN ENNUSTEET (kevään ennusteet)

fi_eu15 endogeeninen	Korjatun BKT:n ennustevirheet (ennustettu kasvuaste (%) - toteutunut(%))						
	Malli 1	Malli 2	Malli 3	Malli 4	Malli 5	Malli 6	Malli 7
2010	-1,918	-2,108	-1,975	-2,172	-1,999	-2,057	-2,172
2011	-2,619	-2,424	-2,796	-2,621	-2,633	-2,817	-2,431
2011	-1,274	-1,311	-1,236	-1,274	-1,198	-1,159	-1,145
2012	1,116	1,112	1,216	1,202	1,116	1,224	1,295
2012	0,091	-0,122	0,138	-0,084	-0,027	0,013	0,085
2013	1,654	1,902	1,699	1,920	1,624	1,649	1,828
2013	-0,180	-0,209	-0,152	-0,184	-0,184	-0,157	-0,048
2014	0,791	0,891	0,769	0,868	0,739	0,716	0,499
2014	1,004	0,908	0,961	0,865	0,890	0,845	0,892
2015	0,194	0,285	0,043	0,130	0,163	-0,002	0,025
2015	0,377	0,525	0,326	0,480	0,304	0,253	0,434
2016	-0,135	-0,306	-0,289	-0,436	-0,159	-0,319	-0,120
Neliösumma	18,012	19,024	19,362	20,321	17,766	19,142	18,213
Ennustevirheiden itseisarvojen keskiarvo	0,946	1,009	0,967	1,020	0,920	0,934	0,915

fi_eu15 eksogeeninen	Korjatun BKT:n ennustevirheet (ennustettu kasvuaste (%) - toteutunut(%))						
	Malli 1	Malli 2	Malli 3	Malli 4	Malli 5	Malli 6	Malli 7
2010	-1,955	-2,200	-2,227	-2,275	-2,043	-2,104	-2,227
2011	-2,952	-2,937	-2,988	-3,244	-3,015	-3,267	-3,017
2011	-1,320	-1,361	-1,156	-1,337	-1,242	-1,216	-1,193
2012	0,771	0,693	1,024	0,637	0,784	0,763	0,886
2012	0,110	-0,146	0,350	-0,119	-0,014	0,025	0,166
2013	1,503	1,598	1,671	1,517	1,423	1,385	1,486
2013	-0,258	-0,315	-0,167	-0,315	-0,265	-0,260	-0,167
2014	0,275	0,316	0,071	0,106	0,189	-0,016	0,048
2014	0,951	0,823	0,887	0,767	0,830	0,776	0,797
2015	-0,139	-0,146	-0,252	-0,400	-0,224	-0,479	-0,320
2015	0,299	0,467	0,449	0,417	0,220	0,156	0,350
2016	-0,522	-0,636	-0,687	-0,830	-0,588	-0,851	-0,765
Neliösumma	18,571	19,899	20,744	21,933	18,687	20,731	19,986
Ennustevirheiden itseisarvojen keskiarvo	0,921	0,970	0,994	0,997	0,903	0,942	0,952

log(fi_eu15) eksogeeninen	Korjatun BKT:n ennustevirheet (ennustettu kasvuaste (%) - toteutunut(%))						
	Malli 1	Malli 2	Malli 3	Malli 4	Malli 5	Malli 6	Malli 7
2010	-1,965	-2,225	-2,267	-2,322	-2,062	-2,139	-2,269
2011	-2,990	-2,981	-3,063	-3,337	-3,074	-3,368	-3,097
2011	-1,308	-1,343	-1,148	-1,330	-1,233	-1,218	-1,186
2012	0,751	0,663	0,998	0,574	0,752	0,702	0,864
2012	0,110	-0,160	0,356	-0,144	-0,019	0,010	0,175
2013	1,466	1,562	1,616	1,441	1,373	1,299	1,427
2013	-0,277	-0,337	-0,195	-0,351	-0,288	-0,295	-0,195
2014	0,247	0,294	-0,004	0,039	0,148	-0,098	-0,030
2014	0,946	0,814	0,861	0,741	0,820	0,751	0,774
2015	-0,153	-0,162	-0,302	-0,455	-0,253	-0,545	-0,375
2015	0,266	0,444	0,410	0,377	0,183	0,101	0,313
2016	-0,553	-0,672	-0,752	-0,903	-0,631	-0,936	-0,835
Neliösumma	18,670	20,087	21,184	22,564	18,944	21,423	20,535
Ennustevirheiden itseisarvojen keskiarvo	0,919	0,971	0,998	1,001	0,903	0,955	0,962

Liite 7: VARX-mallien yhtälöt

**Malli 1**

Sample (adjusted): 1990Q3 2016Q4  
 Included observations: 106 after adjustments  
 Standard errors in ( ) & t-statistics in [ ]

	DLOG(BKT...	DLOG(I)	U_SEAS2	DLOG(BKT28)
DLOG(BKTADJ(-1))	-0.221926 (0.10808) [-2.05339]	0.782916 (0.33423) [2.34243]	-0.138397 (0.04849) [-2.85410]	-0.043066 (0.05018) [-0.85827]
DLOG(I(-1))	0.118193 (0.03063) [3.85937]	0.150934 (0.09471) [1.59367]	-0.075412 (0.01374) [-5.48840]	0.001975 (0.01422) [0.13889]
U_SEAS2(-1)	0.035677 (0.03857) [0.92489]	0.168862 (0.11929) [1.41554]	1.013309 (0.01731) [58.5497]	0.023768 (0.01791) [1.32713]
DLOG(BKT28(-1))	0.877741 (0.21958) [3.99735]	1.081038 (0.67906) [1.59197]	-0.069361 (0.09852) [-0.70405]	0.674100 (0.10195) [6.61234]
C	-0.000247 (0.00445) [-0.05542]	-0.022138 (0.01376) [-1.60900]	-9.91E-05 (0.00200) [-0.04963]	-0.000641 (0.00207) [-0.31032]
LOG(FI_EU15(-1))	-0.046732 (0.01835) [-2.54644]	-0.000452 (0.05675) [-0.00796]	0.004067 (0.00823) [0.49392]	-0.004328 (0.00852) [-0.50801]
R-squared	0.468123	0.354618	0.984037	0.467107
Adj. R-squared	0.441529	0.322349	0.983239	0.440463
Sum sq. resids	0.007706	0.073702	0.001551	0.001661
S.E. equation	0.008779	0.027148	0.003939	0.004076
F-statistic	17.60269	10.98939	1232.909	17.53101
Log likelihood	354.6367	234.9640	439.5938	435.9683
Akaike AIC	-6.578051	-4.320076	-8.181014	-8.112610
Schwarz SC	-6.427290	-4.169315	-8.030254	-7.961849
Mean dependent	0.003882	0.001622	0.097860	0.004013
S.D. dependent	0.011747	0.032979	0.030423	0.005449
Determinant resid covariance (dof adj.)		8.65E-18		
Determinant resid covariance		6.85E-18		
Log likelihood		1493.056		
Akaike information criterion		-27.71804		
Schwarz criterion		-27.11500		
Number of coefficients		24		

**Malli 2**

Sample (adjusted): 1990Q3 2016Q4  
 Included observations: 106 after adjustments  
 Standard errors in ( ) & t-statistics in [ ]

	DLOG(BKT...	U_SEAS2	DLOG(BKT28)
DLOG(BKTADJ(-1))	-0.149019 (0.11275) [-1.32162]	-0.187306 (0.05398) [-3.47004]	-0.042196 (0.04914) [-0.85863]
U_SEAS2(-1)	0.041877 (0.04031) [1.03896]	1.011155 (0.01930) [52.4036]	0.024105 (0.01757) [1.37213]
DLOG(BKT28(-1))	1.066068 (0.22730) [4.69020]	-0.189188 (0.10881) [-1.73867]	0.677301 (0.09907) [6.83688]
C	0.052228 (0.02207) [2.36697]	-0.009893 (0.01056) [-0.93656]	0.003512 (0.00962) [0.36516]
FI_EU15(-1)	-0.053539 (0.01839) [-2.91082]	0.010303 (0.00881) [1.17006]	-0.004192 (0.00802) [-0.52293]
R-squared	0.396355	0.979374	0.467006
Adj. R-squared	0.372448	0.978558	0.445897
Sum sq. resids	0.008746	0.002004	0.001661
S.E. equation	0.009306	0.004455	0.004056
F-statistic	16.57922	1198.960	22.12388
Log likelihood	347.9282	426.0117	435.9582
Akaike AIC	-6.470344	-7.943616	-8.131287
Schwarz SC	-6.344710	-7.817982	-8.005653
Mean dependent	0.003882	0.097860	0.004013
S.D. dependent	0.011747	0.030423	0.005449
Determinant resid covariance (dof adj.)		1.88E-14	
Determinant resid covariance		1.62E-14	
Log likelihood		1231.617	
Akaike information criterion		-22.95503	
Schwarz criterion		-22.57813	
Number of coefficients		15	



### Malli 3

Sample (adjusted): 1990Q3 2016Q4  
 Included observations: 106 after adjustments  
 Standard errors in ( ) & t-statistics in [ ]

	DLOG(BKT...	DLOG(I)	DLOG(BKT28)
DLOG(BKTADJ(-1))	-0.222182 (0.10800) [-2.05724]	0.781703 (0.33589) [ 2.32727]	-0.043237 (0.05037) [-0.85845]
DLOG(I(-1))	0.120069 (0.03054) [ 3.93205]	0.159810 (0.09497) [ 1.68276]	0.003224 (0.01424) [ 0.22640]
DLOG(BKT28(-1))	0.884842 (0.21929) [ 4.03504]	1.114647 (0.68201) [ 1.63436]	0.678830 (0.10227) [ 6.63785]
C	0.003685 (0.00131) [ 2.80537]	-0.003531 (0.00408) [-0.86441]	0.001978 (0.00061) [ 3.22917]
LOG(FI_EU15(-1))	-0.057599 (0.01409) [-4.08862]	-0.051886 (0.04381) [-1.18423]	-0.011568 (0.00657) [-1.76075]
R-squared	0.463573	0.341686	0.457722
Adj. R-squared	0.442329	0.315614	0.436245
Sum sq. resids	0.007772	0.075179	0.001690
S.E. equation	0.008772	0.027283	0.004091
F-statistic	21.82074	13.10555	21.31280
Log likelihood	354.1852	233.9125	435.0430
Akaike AIC	-6.588401	-4.319104	-8.114018
Schwarz SC	-6.462767	-4.193470	-7.988384
Mean dependent	0.003882	0.001622	0.004013
S.D. dependent	0.011747	0.032979	0.005449
Determinant resid covariance (dof adj.)		6.13E-13	
Determinant resid covariance		5.30E-13	
Log likelihood		1046.824	
Akaike information criterion		-19.46839	
Schwarz criterion		-19.09148	
Number of coefficients		15	

### Malli 4

Sample (adjusted): 1990Q3 2016Q4  
 Included observations: 106 after adjustments  
 Standard errors in ( ) & t-statistics in [ ]

	DLOG(BKT...	DLOG(BKT28)
DLOG(BKTADJ(-1))	-0.133508 (0.11286) [-1.18297]	-0.040856 (0.04903) [-0.83334]
DLOG(BKT28(-1))	1.073852 (0.22862) [ 4.69710]	0.683906 (0.09931) [ 6.88628]
C	0.003058 (0.00139) [ 2.19524]	0.001961 (0.00061) [ 3.24063]
LOG(FI_EU15(-1))	-0.066181 (0.01487) [-4.45021]	-0.011798 (0.00646) [-1.82629]
R-squared	0.381458	0.457446
Adj. R-squared	0.363265	0.441489
Sum sq. resids	0.008962	0.001691
S.E. equation	0.009374	0.004072
F-statistic	20.96794	28.66662
Log likelihood	346.6361	435.0161
Akaike AIC	-6.464833	-8.132379
Schwarz SC	-6.364326	-8.031872
Mean dependent	0.003882	0.004013
S.D. dependent	0.011747	0.005449
Determinant resid covariance (dof adj.)		1.07E-09
Determinant resid covariance		9.88E-10
Log likelihood		798.1444
Akaike information criterion		-14.90839
Schwarz criterion		-14.70737
Number of coefficients		8

## Malli 5

Sample (adjusted): 1990Q3 2016Q4  
 Included observations: 106 after adjustments  
 Standard errors in ( ) & t-statistics in [ ]

	DLOG(BKT...	DLOG(I)	U_SEAS2	DLOG(BKT28)	DLOG(LC...
DLOG(BKTADJ(-1))	-0.247443 (0.10955) [-2.25870]	0.622835 (0.33019) [ 1.88630]	-0.133712 (0.04948) [-2.70215]	-0.050290 (0.05110) [-0.98409]	0.043856 (0.11602) [ 0.37802]
DLOG(I(-1))	0.122611 (0.03144) [ 3.90034]	0.204673 (0.09475) [ 2.16018]	-0.075425 (0.01420) [-5.31186]	0.004544 (0.01466) [ 0.30987]	0.042015 (0.03329) [ 1.26204]
U_SEAS2(-1)	0.033567 (0.03797) [ 0.88404]	0.139034 (0.11444) [ 1.21489]	1.015701 (0.01715) [ 59.2220]	0.023435 (0.01771) [ 1.32311]	-0.027980 (0.04021) [-0.69584]
DLOG(BKT28(-1))	0.858779 (0.22055) [ 3.89379]	0.892732 (0.66474) [ 1.34297]	-0.069756 (0.09962) [-0.70021]	0.664450 (0.10288) [ 6.45840]	0.115725 (0.23357) [ 0.49547]
DLOG(LCOST(-1))	0.100785 (0.09730) [ 1.03582]	0.770164 (0.29327) [ 2.62617]	-0.007951 (0.04395) [-0.18091]	0.038296 (0.04539) [ 0.84374]	-0.173546 (0.10304) [-1.68422]
C	0.048786 (0.02094) [ 2.32989]	0.012868 (0.06311) [ 0.20390]	-0.006266 (0.00946) [-0.66253]	0.004349 (0.00977) [ 0.44528]	0.006149 (0.02217) [ 0.27732]
FI_EU15(-1)	-0.049100 (0.01759) [-2.79071]	-0.034616 (0.05303) [-0.65276]	0.005874 (0.00795) [ 0.73908]	-0.005114 (0.00821) [-0.62307]	0.003998 (0.01863) [ 0.21459]
R-squared	0.476870	0.397050	0.984087	0.470890	0.074147
Adj. R-squared	0.445166	0.360507	0.983122	0.438823	0.018035
Sum sq. resids	0.007580	0.068857	0.001546	0.001649	0.008501
S.E. equation	0.008750	0.026373	0.003952	0.004082	0.009266
F-statistic	15.04094	10.86545	1020.378	14.68445	1.321406
Log likelihood	355.5156	238.5685	439.7590	436.3459	349.4376
Akaike AIC	-6.575765	-4.369216	-8.165264	-8.100866	-6.461087
Schwarz SC	-6.399878	-4.193329	-7.989377	-7.924978	-6.285199
Mean dependent	0.003882	0.001622	0.097860	0.004013	0.007036
S.D. dependent	0.011747	0.032979	0.030423	0.005449	0.009351
Determinant resid covariance (dof adj.)	6.30E-22				
Determinant resid covariance	4.48E-22				
Log likelihood	1853.349				
Akaike information criterion	-34.30846				
Schwarz criterion	-33.42903				
Number of coefficients	35				

## Malli 6

Sample (adjusted): 1990Q3 2016Q4  
 Included observations: 106 after adjustments  
 Standard errors in ( ) & t-statistics in [ ]

	DLOG(BKT...	DLOG(I)	DLOG(BKT28)	DLOG(LC...
DLOG(BKTADJ(-1))	-0.240004 (0.10931) [-2.19572]	0.645749 (0.33059) [ 1.95334]	-0.050345 (0.05105) [-0.98619]	0.037711 (0.11535) [ 0.32693]
DLOG(I(-1))	0.127572 (0.03136) [ 4.06754]	0.217046 (0.09486) [ 2.28815]	0.006216 (0.01465) [ 0.42439]	0.039506 (0.03310) [ 1.19364]
DLOG(BKT28(-1))	0.857348 (0.22079) [ 3.88317]	0.904915 (0.66775) [ 1.35517]	0.667866 (0.10311) [ 6.47695]	0.113508 (0.23299) [ 0.48718]
DLOG(LCOST(-1))	0.101342 (0.09738) [ 1.04067]	0.773053 (0.29452) [ 2.62477]	0.040415 (0.04548) [ 0.88863]	-0.173435 (0.10276) [-1.68771]
C	0.003239 (0.00138) [ 2.34600]	-0.006927 (0.00418) [-1.65871]	0.001800 (0.00064) [ 2.79175]	0.007192 (0.00146) [ 4.93568]
LOG(FI_EU15(-1))	-0.059924 (0.01426) [-4.20285]	-0.069625 (0.04312) [-1.61459]	-0.012495 (0.00666) [-1.87645]	0.010215 (0.01505) [ 0.67893]
R-squared	0.469321	0.384117	0.461970	0.067418
Adj. R-squared	0.442787	0.353322	0.435069	0.020789
Sum sq. resids	0.007689	0.070334	0.001677	0.008563
S.E. equation	0.008769	0.026520	0.004095	0.009253
F-statistic	17.68753	12.47367	17.17267	1.445832
Log likelihood	354.7561	237.4436	435.4599	349.0538
Akaike AIC	-6.580304	-4.366861	-8.103016	-6.472713
Schwarz SC	-6.429544	-4.216100	-7.952255	-6.321952
Mean dependent	0.003882	0.001622	0.004013	0.007036
S.D. dependent	0.011747	0.032979	0.005449	0.009351
Determinant resid covariance (dof adj.)	4.53E-17			
Determinant resid covariance	3.59E-17			
Log likelihood	1405.233			
Akaike information criterion	-26.06101			
Schwarz criterion	-25.45796			
Number of coefficients	24			

## Malli 7

Sample (adjusted): 1990Q4 2016Q4

Included observations: 105 after adjustments

Standard errors in ( ) & t-statistics in [ ]

	DLOG(BKT...	DLOG(I)	DLOG(BKT28)	DLOG(LC...
DLOG(BKTADJ(-1))	-0.356490 (0.11919) [-2.99094]	0.663850 (0.34766) [ 1.90949]	-0.061156 (0.05719) [-1.06945]	0.052408 (0.12979) [ 0.40380]
DLOG(BKTADJ(-2))	-0.177066 (0.11469) [-1.54393]	0.757879 (0.33452) [ 2.26558]	-0.026291 (0.05502) [-0.47782]	0.073179 (0.12488) [ 0.58598]
DLOG(I(-1))	0.120582 (0.03594) [ 3.35501]	0.043496 (0.10483) [ 0.41491]	0.008329 (0.01724) [ 0.48303]	0.034958 (0.03914) [ 0.89324]
DLOG(I(-2))	0.076296 (0.03516) [ 2.17012]	0.044571 (0.10255) [ 0.43463]	0.004796 (0.01687) [ 0.28432]	-0.001377 (0.03828) [-0.03596]
DLOG(BKT28(-1))	1.008283 (0.25791) [ 3.90946]	0.355723 (0.75228) [ 0.47286]	0.724517 (0.12374) [ 5.85517]	0.119220 (0.28084) [ 0.42451]
DLOG(BKT28(-2))	0.002962 (0.26109) [ 0.01135]	0.670758 (0.76157) [ 0.88076]	-0.050317 (0.12527) [-0.40167]	-0.109765 (0.28431) [-0.38608]
DLOG(LCOST(-1))	0.097828 (0.10262) [ 0.95326]	0.492089 (0.29934) [ 1.64391]	0.042389 (0.04924) [ 0.86090]	-0.181044 (0.11175) [-1.62008]
DLOG(LCOST(-2))	0.104453 (0.10117) [ 1.03243]	-0.004275 (0.29510) [-0.01449]	0.000377 (0.04854) [ 0.00777]	0.003027 (0.11017) [ 0.02748]
C	0.003411 (0.00154) [ 2.21397]	-0.009759 (0.00449) [-2.17154]	0.001948 (0.00074) [ 2.63531]	0.007185 (0.00168) [ 4.28305]
LOG(FI_EU15(-1))	-0.068417 (0.01552) [-4.40921]	-0.025656 (0.04526) [-0.56685]	-0.013099 (0.00744) [-1.75954]	0.012542 (0.01690) [ 0.74226]
R-squared	0.491802	0.450702	0.467272	0.072047
Adj. R-squared	0.443657	0.398664	0.416803	-0.015864
Sum sq. resids	0.007182	0.061103	0.001653	0.008516
S.E. equation	0.008695	0.025361	0.004172	0.009468
F-statistic	10.21500	8.660900	9.258595	0.819545
Log likelihood	354.4945	242.0918	431.6090	345.5503
Akaike AIC	-6.561800	-4.420797	-8.030648	-6.391434
Schwarz SC	-6.309042	-4.168039	-7.777889	-6.138675
Mean dependent	0.004061	0.002138	0.004049	0.007015
S.D. dependent	0.011657	0.032705	0.005463	0.009394
Determinant resid covariance (dof adj.)		4.12E-17		
Determinant resid covariance		2.76E-17		
Log likelihood		1405.818		
Akaike information criterion		-26.01557		
Schwarz criterion		-25.00454		
Number of coefficients		40		

Liite 8: Muuttujien herkkyyssanalyysi

Kahden vuoden kasvuaste-ennusteiden keskimääräinen muutos positiivisen mittausvirheen seurauksena

		Malli 3			Malli 4		Malli 6			
		BKT28	BKTADJ	I	BKT28	BKTADJ	BKT28	BKTADJ	I	LCOST
BKTADJ kasvuasteen mittausvirhe 0,5 prosenttiyksikköä	1. vuosi	-0,037%	0,306%	0,386%	-0,038%	0,307%	-0,039%	0,303%	0,371%	0,025%
	2. vuosi	-0,020%	0,022%	-0,013%	-0,019%	0,011%	-0,017%	0,029%	0,019%	0,000%
I kasvuasteen mittausvirhe 0,5 prosenttiyksikköä	1. vuosi	0,000%	-0,059%	-0,505%			-0,004%	-0,070%	-0,564%	-0,027%
	2. vuosi	0,002%	-0,005%	-0,067%			-0,002%	-0,015%	-0,107%	-0,006%
FI_EU15 kasvuasteen mittausvirhe 0,5 prosenttiyksikköä	1. vuosi	-0,023%	-0,082%	-0,144%	-0,023%	-0,090%	-0,025%	-0,086%	-0,168%	0,020%
	2. vuosi	-0,054%	-0,162%	-0,350%	-0,053%	-0,164%	-0,057%	-0,171%	-0,391%	0,014%
BKT28 kasvuasteen mittausvirhe 0,5 prosenttiyksikköä	1. vuosi	1,011%	0,825%	1,452%	1,014%	0,916%	0,990%	0,773%	1,164%	0,174%
	2. vuosi	0,376%	0,521%	1,347%	0,374%	0,473%	0,368%	0,502%	1,294%	0,144%
LCOST kasvuasteen mittausvirhe 0,5 prosenttiyksikköä	1. vuosi						0,043%	0,105%	0,573%	0,331%
	2. vuosi						0,021%	0,052%	0,177%	0,056%

*Liite 9: Ennusteet vuosille 2017 ja 2018*

**Ennuste 2017Q1-2018Q4**

VARX-malli		BKT28	BKADJ	I	LCOST
Malli 3	2017	1,8%	1,8%	3,9%	
	2018	1,4%	0,9%	0,0%	
Maltillinen malli 3	2017	1,8%	1,8%	3,9%	
	2018	1,4%	1,2%	0,3%	
Malli 4	2017	1,8%	1,4%		
	2018	1,4%	0,6%		
Malli 6	2017	1,7%	1,5%	1,8%	2,2%
	2018	1,3%	0,6%	-1,5%	2,9%
Keskiarvo	2017	1,8%	1,6%	2,8%	2,2%
	2018	1,3%	0,7%	-0,7%	2,9%

**Ennuste 2017Q2-2018Q4**

VARX-malli		BKT28	BKADJ	I	LCOST
Malli 3	2017	2,0%	2,9%	9,7%	
	2018	1,4%	1,3%	1,9%	
Maltillinen malli 3	2017	2,0%	2,9%	9,7%	
	2018	1,5%	1,6%	2,2%	
Malli 4	2017	1,9%	2,3%		
	2018	1,4%	0,7%		
Malli 6	2017	1,9%	2,7%	8,7%	1,0%
	2018	1,3%	0,9%	-0,3%	3,0%
Keskiarvo	2017	1,9%	2,7%	9,2%	1,0%
	2018	1,4%	0,9%	0,8%	3,0%

**Ennuste 2017Q4-2018Q4**

VARX-malli		BKT28	BKADJ	I	LCOST
Malli 3	2017	2,4%	3,2%	11,0%	
	2018	2,0%	2,1%	4,2%	
Maltillinen malli 3	2017	2,4%	3,2%	11,0%	
	2018	2,0%	2,3%	4,3%	
Malli 4	2017	2,4%	3,1%		
	2018	1,9%	1,6%		
Malli 6	2017	2,4%	3,1%	10,7%	0,1%
	2018	1,9%	1,7%	2,2%	2,4%
Keskiarvo	2017	2,4%	3,1%	10,9%	0,1%
	2018	1,9%	1,8%	3,2%	2,4%