

Terveysmenot maakunnittain 1993–2026: Aikasarjaennusteet kunta-aineistolla

Mika Lindén

Sosiaali- ja terveyspalvelu-uudistuksen, soten, eräänä tavoitteena on saada julkisten terveysmenojen kasvu hallintaan 2020-luvun aikana. Hallituksen sote-esityksen mukaan nykyinen kuntapohjainen sote-järjestelmä ei pysty tähän ja vaan se on korvattava maakunta- ja valinnanvapausmallilla. Artikkelissa muodostetaan Suomen kuntien vuosien 1993–2016 terveystoiminnan nettomenoaikasarjojen avulla maakuntien tulevan kehityksen ennusteet vuosille 2017–2026 kahdella aikasarjamallilla ja niiden yhdistelmän avulla. Saatujen tulosten mukaan terveystoiminnan nettomenot nousevat eri maakunnissa 25–35 prosenttia vuoteen 2026 mennessä vuoden 2016 tasosta. Kuntatietojen käyttöä maakuntaennusteiden pohjana sote-uudistuksen yhteydessä perustellaan sillä, että uudistus ei anna aihetta olettaa, että terveysmenojen taustalla olevat terveyspalveluiden kysyntä- ja tarjontatekijät tulisivat muuttumaan sote-uudistuksen myötä menoja rajaavaan suuntaan ilman valtiovarainministeriön budjettiobjausta.

Sote- ja maakuntauudistuksen mukaan maakuntien merkitys kasvaa erityisesti julkisten terveysmenojen kohdalla. Nykyinen kuntapohjainen rahoitusjärjestelmä lakkaa ja maakunnista tulee terveyspalveluiden järjestäjiä, rahoittajia ja erityisesti erikoissairaanhoidossa myös tuottajia. Mikä tulee olemaan maakuntatasoisen järjestelmän sosiaali- ja terveysmenojen kehitys uudistuksen jälkeen, on ensisijaisen tärkeä kysymys arvioitaessa sote-uudistuksen

onnistumista. Koska tulevan järjestelmän menorakenne ja arvioidut kustannukset ovat vielä varsin epäselvät ja muotoutuvat vasta uuden järjestelmän liikkeelle lähdön kuluessa, mitään tarkkaa arviota ei voida antaa tulevien vuosien menojen tasosta ja kehityslinjoista maakuntien kohdalla.

Sote- ja maakuntauudistuksen eräs keskeinen tavoite verrattuna nykyiseen kuntapohjaiseen järjestelmään on saada sosiaali- ja terveys-

VTT Mika Lindén (mika.linden@uef.fi) on kansantaloustieteen professori (terveystaloustiede) Itä-Suomen yliopistossa. Kiitän kahta anonymia lausunnonantajaa ja Antti Suvantoa hyödyllisistä ja rakentavista kommentteista.

menojen kehitys keskittyneempään hallintaan ja suunnitelmallisempaan poliittiseen ohjaukseen väestön ikääntymisen ja yksityisen palvelutuotannon kasvun myötä. Uudistus antaa hyvän mahdollisuuden tulevina vuosina tutkia miten maakuntatasoiset menot tulevat kehittymään kun vertailupohjana pidetään nykyisen kuntapohjaisen järjestelmän menokehityksen ennusteita.

Seuraavassa ei siis tutkita sitä, miten sosiaali- ja terveystenot tulevat kehittymään tulevia vuosina uuden sote-järjestelmän yhteydessä. Sen sijaan mielenkiinnon kohteena ovat paljon esillä olleet kuntien terveystenot, so. kuntien nettoterveystenot vuosina 1993–2016, jotka muodostavat kunnasta riippuen 50–60 % niiden sosiaali- ja terveystenosta. Sosiaalimeinonihin verrattuna kuntien terveydenhuollon menokehitys on nykyisessä järjestelmässä tilastoitu varsin johdonmukaisesti vuoteen 2016 saakka, joten sen pohjalta voidaan muodostaa erilaisia ennusteita ja skenaarioita koskemaan myös tulevaa kehitystä. Tämä muodostaa vertailuperustan sote-uudistukselle.

Pääsääntöisesti nykyisen rakenteen menoja voidaan tutkia kahdella tavalla:

a) Selvitetään varsin tarkkaan *kuntatasolta* lähtien miten eri menoerät määräytyvät eri tekijöiden kautta (esim. kunnan väestön koko, ikä ja sairastavuus) ja ennustetaan näiden tekijöiden arvioidun tulevan kehityksen avulla miten menot kehittyvät. Tämän jälkeen voidaan suorittaa aggregointi maakuntatasolle, ja katsoa mitkä ovat maakuntatason terveystenojen kehityslinjat tulevina vuosina.

b) Tehdään ennusteanalyysi menneen *maakuntakehityksen* turvin ottamatta huomioon menokehitykseen vaikuttavia tekijöitä.

Lähtökohta (a) suoritettuna kelvollisena ekonometrisena analyysinä on suuri ja vaativa hanke, koska kuntien heterogeenisuus on jo terveystenojen tasojen ja vuosimuutosten kohdalla suuri puhumattakaan niihin vaikuttavista tekijöistä. Yksittäiselle kunnalle on varsin helppo löytää keskeiset menokehitystä ohjaavat tekijät, mutta kuntia kokonaisuudessaan tai jopa vain tiettyjä kuntaryhmiä (esim. väestöltään isoimmat kunnat) määrääviä yhteisiä menotekijöitä on varsin vaikeaa perustella (esim. Nguyen ym.; Meklin ja Pukki 2017). Lähtökohdtaa (a) tutkimushankkeena ei puolusta myöskään se, että kuntia Suomessa on noin 300, joille miltei jokaiselle on löydettävä tulevaa menokehitystä ennustavat kuntakohtaiset erityistekijät, joilla suoritetaan kunkin kunnan menoennustus. Tämä lisää huomattavasti aggregoitavan maakuntatason ennusteen epävarmuutta, koska kuntatasoinen ennuste-epävarmuus kumuloituu maakuntatasolle. Tämän lisäksi kuntien välillä on maakuntien sisällä riippuvuusrakenteita (esim. kuntayhtymät ja valtion kunnille antama rahoitus), joiden vaikutus on syytä huomioida tavalla tai toisella maakuntatason ennuste-epävarmuutta arvioitaessa.

Lähtökohta (b) perustuu ainoastaan maakuntatasoiseen menokehityksen aikasarjaominaisuuksiin. Koska ennustavia tekijöitä ei hyödynnetä tulevaa menokehitystä arvioitaessa ja ennusteet rakentuvat yksinomaan menojen aikasarjaprosessin ominaisuuksiin, niin ennusteiden epävarmuus on osin hallittavissa. Aikasarjalähestymistapaa puoltaa myös se, että terveystenot ovat sekä kunta- että maakunta-

tasolla varsin voimakkaasti autokorrelloituneita. Tämä tarkoittaa sitä, että mennyt havaittu menokehitys korreloi voimakkaasti seuraavien vuosien kehityksen kanssa. Lähtökohta (b) ei siis anna vastausta siihen, mitkä tekijät aiheuttavat menojen kehityksen, vaan vastaus saadaan siihen, miten kustannusten trendikäytös on määräytynyt ja miten ennusteet tämän pohjalta tulevat määräytymään. Toisaalta, jos tavoitteena on yksinomaan saada ennusteita tulevan kehityksen tiimoilta, niin aikasarjalähestymistapaa voidaan pitää asiallisena ja jopa ainoana ratkaisuna varsinkin silloin, kun ei ole käytettävissä kuntatasoa yhdistäviä ennustemuuttujia.

Seuraavassa keskitytään siis lähtökohtaan (b), mutta samalla otetaan huomioon se seikka, että myös kuntatasolla voidaan ennustaa aikasarjamallien avulla tulevaa kuntamenojen kehitystä. Tällöin nousee esille mielenkiintoinen kysymys, missä määrin yksi sama aikasarjamalli olisi soveltuva kaikkien kuntien ja maakuntien kohdalla. Koska tilanne ei voi olla tämän kaltainen, vaan kuntien ja maakuntien terveysmenojen ajalliset kehitysprosessit ovat yksityiskohdissaan hyvinkin erilaisia, niin maakuntamallin perusteleminen on syytä tehdä kahdella tavalla. Ensimmäinen on *bottom-up* -ratkaisu, jossa kullekin kunnalle haetaan soveltuvin aikasarjamalli ja näiden kuntamallien ennusteet aggregoidaan maakuntatasolle. Toinen on aggregaattitason malli, jossa soveltuvin malli haetaan suoraan maakunta-aineiston perusteella. Tehtäväksi muodostuu siten ratkaistava kumpi menettelytapa tuo paremmat ennusteet maakuntatasolla.

Asia ei kuitenkaan ole näin yksiviivainen, sillä tässä yhteydessä ennustetta (piste-estimaattia) ja sen epävarmuutta (estimaatin 95 %:n todennäköisyysluottamusväliä) määrää käytetyn

historiallisen aikasarjan pituus (aineiston määrä), aikasarjamallin muoto sekä se, millä kriteerillä ennusteen osuvuutta arvioidaan.

Maakuntaennusteet voitaisiin johtaa myös paneeliaineistomallin avulla, jolloin aineistona käytettäisiin kaikkia maakunnan kuntahavaintoja samanaikaisesti. Hintana olisi kuitenkin se, että tarkastelu sidottaisiin yhden ja saman mallin puitteisiin koskemaan sekä kunta- ja maakuntatasoa. Koska malli olisi edelleen aikasarjamalli (dynaaminen paneeli-aineistomalli), niin sitä voitaisiin helposti verrata ennustekyvyltään johonkin toiseen mallitösmennykseen. Tämä ratkaisu ei kuitenkaan ole niin suoraviivainen kuin se antaa ymmärtää, sillä dynaamisten aikasarjamallien harhaton ja tarkentuva estimointi on hankalaa pienissä otoksissa ($T < 20$ havaintoa) ja näiden mallien ennusteominaisuudet ovat teoreettisesti paljolti vielä tuntemattomia. Tässä yhteydessä paneelimallit sivuutetaan.

Pelkästään aikasarjapainottunut kansainvälinen kirjallisuus aiheen tiimoilta ei ole kovinkaan laaja. Lähimmäksi tätä tutkimusta tulevat MaCurdy ja Hansen (2013) ja Zhao (2015), joista edellinen tutki ARIMA-mallien pitkän aikavälin epävarmuustekijöitä Yhdysvaltojen terveydenhoitomenojen ennusteissa. Zhao puolestaan keskittyi OECD-maihin vuosina 1972–2008 tekemällä varsin tyhjentävän ennustevirheanalyysin vuosille 1995–2008 eri aikasarjamallien avulla eri lähteistä saataville terveysmenosarjoille. Mukana tarkastelussa on myös paneeliaineistomallit ja VAR-mallit, joiden avulla tehdään maakohtaiset (20 maata) vuosien 2015, 2020 ja 2025 ennusteet. Terveysmenojen ennustaminen on pääsääntöisesti tapahtunut menojen selitysmallien kautta, jolloin pohjana on varsin laaja kirjallisuus terveysmenojen määräytymisestä eri maissa (esim. Fogel

2008; Astolfi ym. 2012; De La Maisonneuve ja Oliveira Martins 2013; Sheiner 2014). Keskeinen tulos tässä kirjallisuudessa on, että terveysmenojen BKT-jousto on yllättävän usein suurempi kuin yksi, joka johtaa siihen, että terveysmenojen BKT-osuus tulee kasvamaan tulevaisuudessakin. Taustatekijöinä tässä menokehityksessä ovat maksukykyinen väestö ja sen ikääntyminen, tehokkaiden hoitojen kasvava käyttö (hoitoteknologian kustannukset) ja niin sanottu Baumolin tauti. Näiden tekijöiden avulla on luotu pitkän aikavälin menoskenarioita mutta ei niinkään ekonometrisia ennusteita, joiden epävarmuustekijöitä pyritään hallitsemaan.

1. Aineisto

Tutkimus keskittyy Suomen kuntien terveystoimen nimellisiin nettokäyttökustannuksiin (THL 2017b). Indikaattori ilmaisee laskennalliset kuntien terveystoimen nettokäyttökustannukset tuhansina euroina. Käyttökustannuksiin lasketaan toimintamenot ja poistot sekä arvonalentumiset ja vyörytysmenot. Käyttötuotoihin lasketaan toimintatulot ja vyörytystulot. Nettokäyttökustannukset saadaan vähentämällä käyttökustannuksista käyttötuotot. Kuntien maksut kuntayhtymille tulevat mukaan kuntien kautta, sen sijaan kuntayhtymien muut tulot tai menot eivät ole mukana luvuissa.

Tilastouudistuksen takia vuodet 2015 ja 2016 eivät ole täysin vertailukelpoisia aikaisempien vuosien kanssa (Kuntaliitto 2017). Vuosina 2006–2012 Kainuun hallintokokeilualueen kunnat (Hyrnsalmi, Kajaani, Kuhmo, Paltamo, Puolanka, Ristijärvi, Sotkamo, Suomussalmi ja Vuolijoki) eivät täyttäneet kuntien talous- ja toimintatilastoa siltä osin kuin toiminta oli

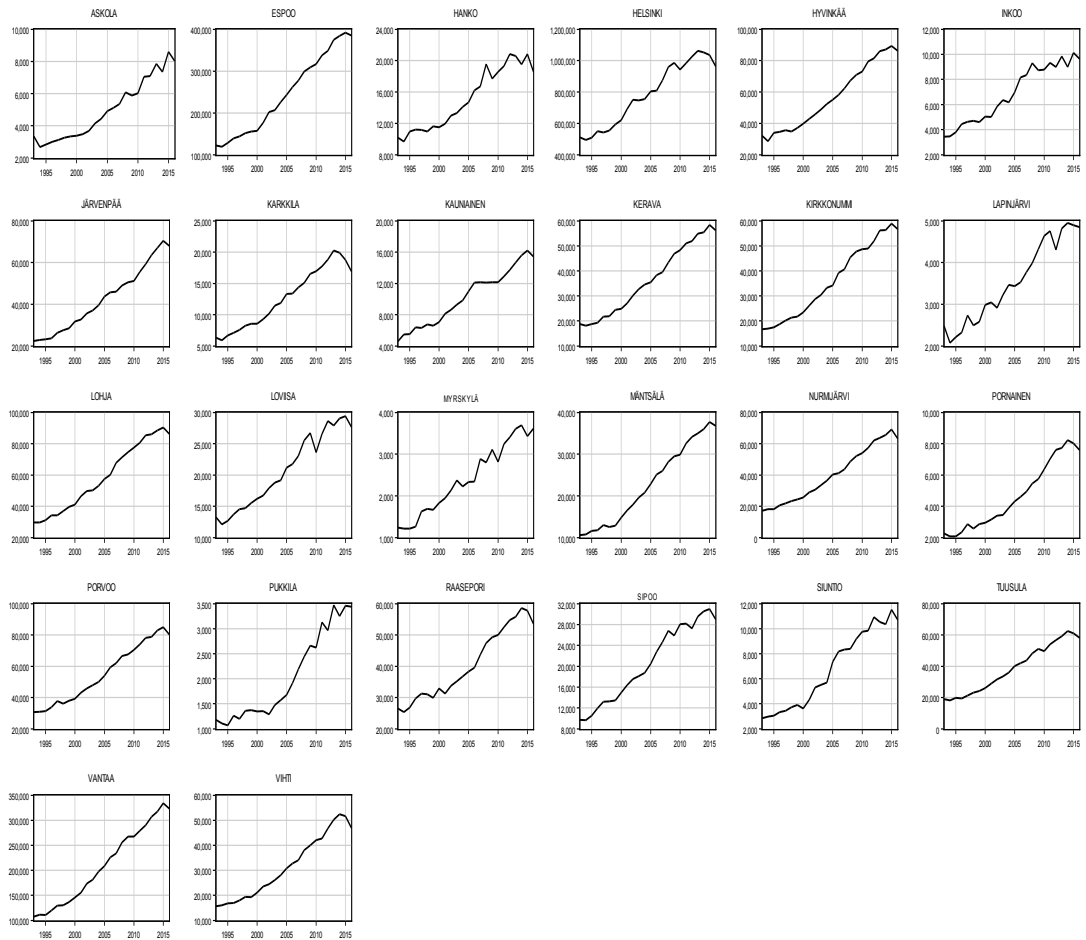
Kainuun maakunta -kuntayhtymän vastuulla. Näiden vuosien kohdalla näille kunnille ajettiin lineaariset regressiot niiden väestömäärien avulla nettomenoille vuosille 1993–2005/2013–2016 ja välivuodet 2006–2012 interpoloitiin kyseessä olevien vuosien väestömäärien avulla regressiotuloksen avulla. Ahvenmaan kunnat eivät kuuluneet tutkimuksen piiriin niiden terveystoiminnan rahoituksen erilaisuuden takia.

2. Kuntien nettomenojen aikasarjamallit

Moderni aikasarjakirjallisuus mahdollistaa hyvinkin suuren mallivaihtoehtojoukon hyödyntämisen. Päälinjajako on lineaaristen (esim. ARIMA-mallit) ja epälineaaristen (esim. kynys- ja bilineaariset mallit) mallien välillä. Koska tehokas täsmennystestaus näiden välillä vaatii suuren otoksen (vähintään $T > 100$) ja usein varsin yksinkertaiset lineaariset mallit ovat riittäviä kuvaamaan aineistoa, niin tässä yhteydessä keskitytään ainoastaan lineaarisiin malleihin.

Kuvio 1 esittää Uudenmaan maakunnan kuntien nettokäyttökustannusten kehityspolut vuosina 1993–2016. Aikasarjat ovat hyvin samanlaisia. Kaikissa esiintyy selkeä trendi ylöspäin erikokoisesta vuosivaihtelusta huolimatta, ja vuosina 2013–2016 nettomenoissa on tapahtunut kunnasta riippuen menojen kasvun taittumista. Suomen muille kunnille kuvat ovat hyvin samanlaisia varsinkin suurten kaupunkikuntien kohdalla, mutta monissa pienissä kunnissa viime vuosien menokehityksen taittumista ei ole havaittavissa. Missä määrin vuosien 2013–2016 nettokäyttökustannuksien notkahdus useissa kunnissa on todellista vai ainoastaan vuosien 2014–2015 tilastouudistuksesta

Kuvio 1. Uudenmaan kuntien terveydenhuollon nettokäyttökustannukset 1993–2016



Lähde: Soskanet, THL.

johtuvaa ei pystytä tässä yhteydessä arvioimaan.

Aikasarja-analyysin puolella kuvion 1 mukaisia sarjoja nimetään trendisarjoiksi, joiden aikasarjamalliin on syytä ottaa trendikomponentti mukaan. Lyhyen aineiston pituuden takia ($T=24$) seuraavassa keskitytään vain kahteen yksinkertaiseen malliin:

Trendistationaarinen TS-malli $Tr+AR(2)$:

$$(1) Y_t = \alpha_1 + \beta_1 Tr_t + c_1 Y_{t-1} + d_1 Y_{t-2} + \varepsilon_t, \quad \varepsilon_t \sim IID(0, \sigma_\varepsilon^2),$$

missä $c_1 + d_1 < 1$.

Differenssistationaarinen DS-malli $DS+ARI(1)$:

$$(2) \Delta Y_t = \alpha_2 + \beta_2 \Delta Y_{t-1} + \mu_t, \quad \mu_t \sim IID(0, \sigma_\mu^2).$$

missä $\Delta Y_t = Y_t - Y_{t-1}$.

Vaikkakin mallit ovat toisistaan varsin poikkeavan näköisiä, niillä on hyvin samanlaiset esitysmuodot, kun differenssimalli (2) kirjoitetaan muodossa

$$(3) Y_t = \alpha_2 + (1 + \beta_2) Y_{t-1} - \beta_2 Y_{t-2} + \mu_t.$$

Malli on trenditermiä lukuun ottamatta samantyyppinen kuin *TS*-malli. Mallien ero on kuitenkin syvällisempi, sillä seuraava *DS*-mallin esitysmuoto on ratkaiseva

$$(4) Y_t = \alpha_2 + Y_{t-1} + \beta_2 (Y_{t-1} - Y_{t-2}) + \mu_t = t \cdot \alpha_2 + \sum_{i=0}^{t-1} \beta_2 (Y_{i+1} - Y_{i+2}) + \sum_{i=0}^t \mu_i$$

Sarjan periodin t realisaatio Y_t muodostuu kolmesta komponentista, joista ensimmäinen on dominoiva kuten *TS*-mallissa, mutta viimeinen komponentti on myös ratkaiseva *DS*-mallissa, sillä riippumattomien satunnaistermien

summa (satunnaiskulku) voi vaeltaa varsin kauas θ -odotusarvotasostaan. Tämä niin sanottu stokastinen trendi kasvattaa mallissa Y_t :n vaihtelevuutta varsin nopeasti ja siten myös sen ennusteen jakaumaa. Keskimmäisen stationaarisen termin osuus mallissa ei ole suuri jos β_2 on pieni ($\beta_2 \approx 0$).

TS-sarjassa vaihtelevuus ei kasva, vaan pysyy vakaana ja samana trendi-kasvun ympärillä. Tärkeä kysymys on, jos trendistationaarisuuden ehto ei pidä paikkaansa, vaan $c_1 + d_1 \approx 1$. Tällöin emme voi erottaa mallia *DS*-mallista, eikä eroa voi pienissä otoksissa testata tehokkaasti.

Seuraavassa estimoidaan molemmat mallit kaikille Suomen kunnille (295 kuntaa) maakuntaryhmissä ja muodostetaan niin sanottu *yhdistetyt ennusteet* varianssipainotusrakenteen

$$(5) w_m = \frac{\frac{1}{m_i} \sum_{i=1}^{m_i} (\hat{\mu}_{m,2016}^i)^2}{\frac{1}{m_i} \sum_{i=1}^{m_i} (\hat{\varepsilon}_{m,2016}^i)^2 + \frac{1}{m_i} \sum_{i=1}^{m_i} (\hat{\mu}_{m,2016}^i)^2} < 1$$

avulla¹. Kaavassa $\hat{\varepsilon}_{m,2016}^i$ kuvaa maakunnan m kaikkien kuntien ($i = 1, 2, \dots, m_k$) *TS*-mallin ennustevirheitä, kun malli on estimoitu havainnoilla 1993–2015 ja sillä on ennustettu kullekin kunnalle vuoden 2016 havainto, toisin sanoen $Y_{m,2016}^i - \hat{Y}_{m,2016}^i = \hat{\varepsilon}_{m,2016}^i$. $\hat{\mu}_{m,2016}^i$ on vastaavasti *DS*-mallin ennustevirhe samalle kunnalle. Yhdistetyt malliennusteet (CS) $Y_{C,2016+h}^i$ vuosille 2017–2026 saadaan näiden vuosien *TS*- ja *DS*-

¹ Voidaan myös johtaa ns. optimaalinen painotus, joka minimoi ennusteiden keskineliövirheen (MSE), kun ennusteet ovat *harbattomia*. Koska *harbattomuus* harvoin toteutuu, niin optimaalinen painotus ei anna välttämättä parempia tuloksia kuin yllä mainittu varianssipainotus. Painotus voidaan johtaa myös ns. Mincer-Zarnowitz (MZ) -regression avulla (esim. Diebold 2017, luku 12).

mallien ennusteiden painotettuna summana seuraavasti

$$(6) Y_{C,2016+h}^i = w_m Y_{TS,2016+h}^i + (1-w_m) Y_{DS,2016+h}^i, \quad h = 1, 2, \dots, 10.$$

Kaava (6) sanoo sen, että jos *TS*-malli on ennustanut paremmin kuin *DS*-malli vuoden 2016 havainnon yli kuntien, toisin sanoen *TS*-mallin vuoden 2016 kuntaennustevirheet ovat suhteellisesti pienempiä eli niiden vaihtelu on pienempää kuin *DS*-mallin, niin sen täytyy saada suurempi paino (iso *w*) yhdistetyssä (*CS*) ennusteissa vuosille 2017–2026.

Seuraavassa johdetaan (so. summataan) maakuntatasoiset *CS*-ennusteet ja niiden 95 %:n luottamusvälit vuosille 2017–2026 *TS*- ja *DS*-mallien painotettujen kuntaennusteiden avulla (painoina vuoden 2016 ennustepainot). Kuntatasolla mallien ennusteiden luottamusvälit lasketaan kyseessä olevien mallien varianssikaavojen avulla (esim. Diebold 2017, luku 7). Tämän jälkeen estimoidaan *TS*- ja *DS*-ennustemallit maakuntahavainnoille ja verrataan niiden antamia vuoden 2017–2026 ennusteita edellä saatuihin painotettuihin *bottom-up*-ennusteisiin.

Ennusteiden otoksen sisäisiä (*with-in sample*) hyvyysmittoja on useita (Diebold 2017, luku 10). Ne keskittyvät arvioimaan ennusteiden harhattomuutta ja vaihtelevuutta kun ennustevirheet $Y_{t+h}^i - \hat{Y}_{t+h|t}^i = \hat{\varepsilon}_{t+h|t}^i$ on laskettavissa.

Keskivirhe (*mean error*, *ME*) vastaa hyvin harhattomuuden kuvaamiseen, toisin sanoen ennusteet osuvat odotusarvomielessä hyvin yhteen toteutuneen kehityksen kanssa

$$(7) ME = \frac{1}{m_k} \sum_{i=1}^{m_k} \hat{\varepsilon}_{t+|t}^i.$$

Jos jonkin ennusteen *ME* on pienempi kuin jonkin toisen, niin tämä ennuste on harhatto-

mampi kuin verrattu ennuste. Koska yksittäiset absoluuttisesti suuret ennustevirheet voivat vaikuttaa *ME*:n arvoon ratkaisevasti, kannattaa myös laskea absoluuttinen keskivirhe (*mean absolute error*, *MAE*) ja absoluuttinen %-keskivirhe (*mean absolute percent error*, *MAPE*)

$$(8) MAE = \frac{1}{m_k} \sum_{i=1}^{m_k} |\hat{\varepsilon}_{t+|t}^i| \quad \text{ja} \quad MAPE = \frac{1}{m_k} \sum_{i=1}^{m_k} |\hat{p}_{t+|t}^i|,$$

missä $\hat{p}_{t+|t}^i$ on $100^* \hat{\varepsilon}_{t+|t}^i / Y_{t+h}^i$.

Ennusteiden vaihtelevuuden eli hajonnan mittoja ovat virheen hajonta (*square of error variance*, *ES*), keskineliövirheen hajonta (*root mean squared error*, *RMSE*)² ja absoluuttisen prosenttikeskineliö-virheen hajonta (*root mean squared percent error*, *RMSPE*):

$$(9) ES = \sqrt{\frac{1}{m_k} \sum_{i=1}^{m_k} (\hat{\varepsilon}_{t+|t}^i - ME)^2}$$

$$(10) RMSE = \sqrt{\frac{1}{m_k} \sum_{i=1}^{m_k} (\hat{\varepsilon}_{t+|t}^i)^2}$$

$$(11) RMSPE = \sqrt{\frac{1}{m_k} \sum_{i=1}^{m_k} (\hat{p}_{t+|t}^i)^2}.$$

Mielenkiintoinen suure on myös Theilin *U*, joka antaa arvion, kuinka paljon pienempi ennusteen neliövirhe on verrattuna sarjan muutoksen neliöön, toisin sanoen ennusteen suhteellinen tarkkuus verrattuna sarjan periodimuutokseen

$$(12) U = \frac{\sum_{i=1}^{m_k} (Y_{t+1}^i - \hat{Y}_{t+1|t}^i)^2}{\sum_{i=1}^{m_k} (Y_{t+1}^i - Y_t^i)^2}.$$

² Tämän neliöllä on tärkeä hajotelma $MSE = ES^2 + ME^2$, josta voidaan laskea osuudet ennusteiden varianssille ja harhan neliölle.

Tässä yhteydessä voidaan käyttää myös Dieboldin ja Marianon S_{DM} -testiä (1995)

$$(13) S_{DM} = (1/\sqrt{m_k/4})(\sum_{i=1}^{m_k} d_i - m_k/2) \sim N(0,1),$$

missä d_i on niiden kertojen lukumäärä kun TS -ennusteen neliöity ennustevirhe $(\hat{\varepsilon}_{t+1|t}^i)^2$ on suurempi kuin DS -mallin ennusteen neliövirhe. Jos $H_0: S_{DM} = 0$ hylätään, ennusteiden välillä on tilastollisesti merkitsevä ero.

3. Ennustetulokset³

Kuvio 2 esittää keskeiset piste-ennusteet vuosille 2017–2026 maakuntien nettokäyttökustannuksille. Kunta- ja maakuntakohtaisten vuosien 1993–2016 kehityksen samankaltaisuuden takia myös näiden sarjojen vuosien 2017–2026 maakuntatason ennusteet ovat myös hyvin samankaltaisia. TS -mallien ennuste kaikille maakunnille on suurempi kuin DS -mallin ennuste ja niiden vuoden 2016 kuntatason ennustetevirheisiin perustuva painotettu yhdistemalli (CS) on tietenkin näiden välissä. Ero mallitulosten välillä on seurausta vuosien 1993–2016 selvästä trendikäytöksestä, jota TS -malli ylläpitää korostuneesti ennusteperiodin alusta lähtien esillä verrattuna DS -malliin, joka vuorostaan säilyttää vuosien 2014–2016 menokehityksen taantumisen ja notkahtamisen selvemmin.

Liite 1 esittää yhteenvedon eri mallien ennuste- ja mallikriteereistä. Siitä nähdään, että S_{DM} -testi löytää tilastollisen eron mallien välille vuonna 2016 vain neljän maakunnan kohdalla, jotka ovat Uusimaa, Päijät-Häme, Pohjois-Savo ja Pohjois-Pohjanmaa. Ainostaan Pohjois-Savon kohdalla TS -ennusteen neliövirheet ovat merkittävästi pienempiä kuin DS -mallin. Uudenmaan, Päijät-Hämeen ja Pohjois-Pohjanmaan kohdalla DS -malli on tarkempi. Liitteen 1 ennustekriteerit vuoden 2016 ennustevirheille osoittavat kuitenkin, että miltei poikkeuksetta yhdistemalli CS antaa tarkimmat tulokset. Täten, jos parhaaksi ennustetulemaksi valitaan yhdiste-ennusteen CS tulokset, niin keskeinen tulos on, että maakunnat jakaantuvat kolmeen ryhmään terveystenonien prosenttikasvun suhteen vuoden 2026 mennessä:

≥ 30 %: Varsinais-Suomi, Pirkanmaa, Päijät-Häme, Kymenlaakso, Pohjois-Savo, Pohjois-Karjala, Keski-Suomi ja Keski-Pohjanmaa,

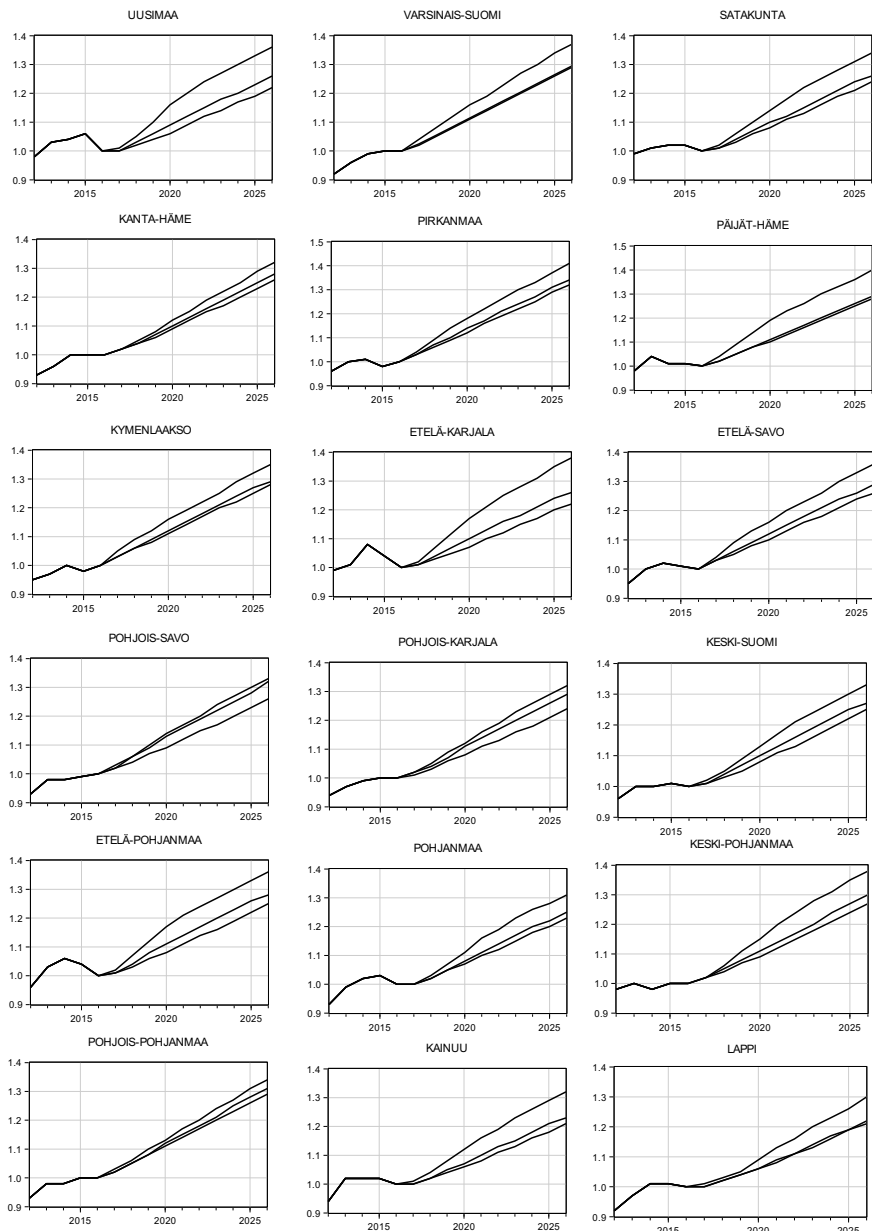
30–25 %: Uusimaa, Satakunta, Kanta-Häme, Etelä-Karjala, Etelä-Savo, Keski-Suomi, Etelä-Pohjanmaa ja Pohjanmaa,

≤ 25 %: Kainuu ja Lappi.

Tämä tulos perustuu kuitenkin piste-ennusteiden varaan eikä huomioi ennusteiden epävarmuutta. Talukko 1 esittää maakuntien vuosien ennusteiden 2017–2026 keskiarvotulomat ja niitä vastaavat normaalijakauman

³ Seuraavassa raportoidaan vain maakuntatason tulokset, koska ne ovat sote-uudistuksen keskiössä. Kuntatason ennusteet annetaan käyttöön pyynnöstä.

Kuvio 2. TS-, DS- ja CS-mallien antamat ennusteet maakuntien nettokäyttökustannusten kehityksestä vuosina 2017–2026 (2016 = 1.00)



Selitykset: Ylin viiva kuua trendistationarisella mallin, alin viiva differenssistationaarisen mallin ja keskellä oleva viiva yhdistetyn mallin antamaa ennustetta.

Taulukko 1. Maakuntien vuoden 2016 terveydenhuollon nettokäyttökustannukset, vuosien 2017–2026 ennusteiden keskiarvot ja niiden 95 %-n normaaliset luottamusvälit

	2016	TS	TS _{0,025}	TS _{0,975}	DS	DS _{0,025}	DS _{0,975}	DS _{0,025}	CS	CS _{0,025}	CS _{0,925}
Uusimaa	2518,8	3031,8	2813,2	3250,3	2783,0	2325,4	3240,6	2325,4	2850,3	2457,3	3243,2
Varsinais-Suomi	885,2	1070,3	1037,5	1103,1	1023,7	933,4	1114,1	933,4	1026,2	938,9	1113,5
Satakunta	424,0	505,3	473,3	537,3	475,3	409,3	541,2	409,3	482,4	424,5	540,3
Kanta-Häme	317,0	370,8	347,2	394,4	359,4	316,2	402,6	316,2	363,2	326,5	399,9
Pirkanmaa	920,1	1134,4	1067,3	1201,4	1079,4	935,9	1222,8	935,9	1094,4	971,8	1217,0
Päijät-Häme	372,4	459,1	433,7	484,5	427,7	360,1	495,4	360,1	430,4	366,4	494,4
Kymenlaakso	349,3	420,2	412,4	427,9	403,1	370,8	435,5	370,8	407,0	380,2	433,8
Etelä-Karjala	250,8	305,4	284,9	325,8	278,7	230,8	326,5	230,8	286,0	245,8	326,3
Etelä-Savo	335,5	405,7	394,5	416,9	384,0	347,2	420,7	347,2	390,6	361,6	419,6
Pohjois-Savo	537,8	636,9	606,5	667,4	610,3	529,9	690,7	529,9	630,5	588,1	673,0
Pohjois-Karjala	338,1	396,4	374,9	417,9	378,9	332,5	425,3	332,5	389,7	358,7	420,8
Keski-Suomi	504,6	595,6	563,4	627,7	566,6	499,6	633,5	499,6	576,5	521,6	631,5
Etelä-Pohjanmaa	380,1	459,9	435,8	484,1	427,6	366,0	489,2	366,0	437,9	388,2	487,5
Pohjanmaa	364,2	424,0	397,7	450,4	405,1	345,9	464,4	345,9	410,1	359,4	460,7
Keski-Pohjanmaa	136,4	165,1	152,3	177,9	155,5	131,2	179,8	131,2	157,8	136,1	179,4
Pohjois-Pohjanmaa	778,3	922,3	875,3	969,3	897,3	811,8	982,8	811,8	906,6	835,5	977,8
Kainuu	171,4	200,5	185,3	215,7	188,6	157,4	219,8	157,4	191,1	163,2	219,0
Lappi	405,1	463,9	430,8	497,0	445,9	377,3	514,6	377,3	447,7	382,6	512,8

Selitykset: TS = trensisistaationaarinen malli, DS = differenssisistaationaarinen malli, CS = yhdistetty malli.

95 %:n luottamusväli⁴. Tämän mukaisesti tulokson luvut vastaavat vuosien 2021–2022 tilanetta.

Seitsemän maakunnan kohdalla vuoden 2016 terveydenhuollon nettokäyttökustannukset ovat ennusteiden 95 %:n luottamusvälin alarajan yläpuolella. Jokaisen maakunnan osalta CS-piste-ennusteet antavat kuitenkin tuloksen, että netto-käyttökustannukset ovat noin 10–20 % korkeampia vuosina 2021–2022 kuin vuonna 2016.

Valtioneuvoston sote-uudistuksen yhtenä perusteena on mainittu 3 miljardin euron reaalin säästö sote-menoissa seuraavan vuosikymmenen aikana. Koska kuntien nettokustannuksista terveydenhuollon osuus on noin 54–56 % riippuen kunnan väestöpohjan koosta (Kuntaliitto 2017), niin runsaan 1,5 miljardin euron säästön pitäisi kohdistua maakuntien terveydenhuoltoon 2020-luvulla. Vuonna 2016 kuntien (ja maakuntien) yhteenlasketut terveydenhuollon nettokäyttökustannukset olivat noin 10 miljardia euroa (THL 2017a, indikaattori 3268, 2018), joista käyttötulojen osuus noin 12 %. Vaikka valtioneuvosto puhuu menoista eikä nettokustannuksista, voidaan tätä

1,5 miljardin säästötavoitetta verrata yllä saattuihin ennustetuloksiin, joiden mukaan nettokäyttökustannukset kasvavat vuoteen 2021–2022 mennessä 10–20 % eli koko maan tasolla kyse on 1,48 miljardin menojen lisäyksestä. Täten seuraavan vuosikymmenen 1,5 miljardin euron säästötavoite tarkoittaisi vuosille 2021–2022 reippaasti alle 1 miljardin kasvumahdollisuutta. Asia voidaan ilmaista myös siten, että nettokäyttökustannusten aiemman vajaan 3 prosentin vuosikasvu-ura jäädytettäisiin noin 1 prosentin tasolle. Tätä voitaneen pitää varsin epärealistisen tavoitteena, ellei nettokäyttökustannuksia leikata myös käyttötulojen (so. palvelumaksujen) kasvattamisen avulla.

4. Yhteenveto

Kuntien terveysmenojen kasvu muiden sotemenojen ohessa on ollut hieman nopeampaa kuin BKT:n per capita -kasvuvauhti keskimäärin vuosina 1993–2016 oli. Vuosien 2008–2016 varsin vaatimaton BKT:n kasvuvauhti välittyi kuntien terveysmenojen kasvuun vasta periodin lopussa. Tämä ei kuitenkaan johtanut terveysmenojen BKT-osuuden suurempaan kasvuun, jonka taso Suomessa on edelleen alle 10 %:a. Siitäkin julkisen rahoituksen osuus on viime vuosina pienentynyt.

Vallitsevan tilanteen taustaksi on syytä todeta, että terveyspalveluiden kysyntä on monessa suhteessa tarjontajohteista myös Suomessa. Sitä tukevat varsin korkea tulojousto, pieni hintajousto ja julkisten palveluiden hyvin matala hintataso. Korkea tulojousto ja kasvava yksityinen terveyspalvelutuotanto nostavat terveysmenojen BKT-osuutta Suomessa myös tulevaisuudessa. On vaikeata nähdä, miten sote-uudistus pienentäisi julkisia menoja. Mi-

⁴ Luottamusvälien laskeminen on perustunut käytettyjen aikasarjamallien rakenteen antamiin virhetermin rakenteisiin. Tällöin puhutaan malli- tai täsmennysepävarmuudesta. Luottamusväli eivät sisällä ns. parametripävarmuutta, joka syntyy siitä, että ennustemallin parametrit täytyy estimoida jollakin menetelmällä. Luottamusväli eivät sisällä myöskään todellista innovaatioepävarmuutta, sillä vuoden 2016 ennustevirheitä käytetään vain kombinoidun ennusteen painorakenteen johtamiseen ja vuosien 2017–2026 ennustevirheiden varianssin laskemiseen käytetään ennustemallien virhetermien varianssia, ts. vuosien 1993–2016 sovitevirheitä. Täten todelliset ex-post -luottamusväli ovat suuremmat kuin yllä raportoidut ex-ante -luottamusväli. Todelliset ennustevirhejaukaumat ovat myös usein ei-normaalaisia.

käli terveydenhoidon peruspalveluiden hintatasoero julkisen ja yksityisen hoidon väliltä häviää ja mitä lähemmäksi sote-tuottajien hintataso asettuu nykyistä kunnallisten terveyskeskusten hintatasoa, sitä suurempaa tulee olemaan palveluiden kysyntä ennen kaikkea hyvätuloisten osalta, sillä heidän maksukykynsä palveluiden suhteen kasvaa entisestään. Näin tapahtui juuri Ruotsissa peruspalvelu-uudistuksen yhteydessä varsinkin suurissa kaupungeissa. Uudistus on tässä mielessä regressiivinen eli hyödyttää eniten niitä, jotka nyt käyttävät tai haluaisivat käyttää yksityisiä palveluita. Mikäli tulevat sote-maakunnat pyrkivät patomaan kasvavan tarjonnan ja kysynnän muodostamia menopaineita, niin seurauksena on jälleen sääntelytilanne, joka terveyspalveluiden tapauksessa tarkoittaa jonoja. Suunnitelmat vähentää palvelutarvetta, joka tarkoittanee tässä yhteydessä käytännössä julkisen palvelutarjonnan rajaamista, ovat poliittisia arvovalintoja. Jää nähtäväksi missä määrin maakuntataso pystyy hallinnoimaan ja hoitamaan jono-ongelman paremmin kuin kuntataso, joka ei suoriudu siitä ilman menoleikkauksiakaan.

Edellä suoritettua kuntien ja maakuntien terveystoiminnan nettokäyttökustannuksien vuosien 2017- 2026 aikasarjaperusteista ennustamista ei voitane pitää turhana hankkeena, vaikka sote-uudistus lupaa mullistaa Suomen terveydenhoitojärjestelmää perusteellisesti. Ihmisten preferenssit, maksuhalukkuus ja palvelutarve terveydenhoidon suhteen tuskin tulevat muuttumaan sote-uudistuksen myötä. Itseasia on odotettavissa että terveyspalveluiden tarjonta ja kysyntä tulevat kasvamaan 2020-luvulla. Koska sote-uudistuksen hallintomallit eivät ole toistaiseksi vakuuttaneet moniakaan menoja laskevana hankkeena ilman VM:n budjettivaltaa, niin suoritettu kunta- ja maakuntatasoinen ennusteanalyysi vuosien 1993–2016 aineistolla puolustaa paikkaansa myös tulevan kehityksen kuvaajana. Saatujen tulosten mukaan terveystoiminnan nettokäyttökustannukset tulevat nousemaan eri maakunnissa 25 % – 35 % vuoteen 2026 mennessä viime vuosien tasosta. Missä määrin näin tulee tai ei tule käymään muodostaa mielenkiintoisen tutkimushaasteen tulevina vuosina. □

Liite 1. Mallien ennuste- ja mallitarkuudet

UUSIMAA	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-10,18	24,85	26,85	10,41	10,18	9,77	203,41	3,14*
DS	-5,19	15,5	16,35	7,39	5,19	6,30	75,42	
MZ	1,39	3,4	3,68	18,48	2,39	11,78	3,81	
CS	1,24	7,38	7,48	7,19	3,83	5,78	15,79	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	5,67	3,86	3,62	1,55	4,52			
DS	4,20	3,76	3,64	1,47	7,42*			
VARSINAIS-SUOMI	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,44	2,89	3,23	5,93	1,45	4,75	80,3	0,96
DS	-0,23	0,73	0,76	5,69	0,53	3,89	4,40	
MZ	-0,52	0,65	0,84	7,29	0,60	5,09	5,37	
CS	-0,30	0,67	0,74	5,66	0,51	3,86	4,19	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	4,39	2,59	2,35	1,87	0,11			
DS	2,95	2,50	2,38	2,09	0,39			
SATAKUNTA	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,64	2,43	2,94	9,24	1,79	7,78	7,33	-1,21
DS	-1,20	1,12	1,64	14,22	1,39	11,29	2,28	
MZ	0,01	0,91	0,91	5,56	0,66	4,29	0,71	
CS	-0,99	1,01	1,41	17,27	1,27	13,07	1,68	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,99	2,18	1,94	1,88	1,18			
DS	2,52	2,08	1,96	1,87	0,87			

KANTA-HÄME	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,02	1,14	1,53	3,82	1,02	3,21	19,35	-0,90
DS	-1,01	0,38	1,08	10,33	1,01	8,18	9,63	
MZ	-0,62	0,37	0,72	6,08	0,67	4,99	4,29	
CS	-1,01	0,38	1,08	10,89	1,01	8,51	9,59	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,54	1,74	1,49	1,88	11,12*			
DS	2,07	1,63	1,51	1,79	10,55*			
PIRKANMAA	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	0,06	5,63	5,63	10,02	2,48	7,23	7,19	0,43
DS	0,15	3,45	3,45	6,61	1,58	5,08	2,70	
MZ	-1,09	1,02	1,49	9,4	1,21	7,38	0,50	
CS	0,27	1,78	1,80	11,44	1,46	8,45	0,73	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	4,65	2,85	2,60	1,99	0,05			
DS	3,20	2,76	2,64	1,91	1,22			
PÄIJÄT-HÄME	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-2,41	2,86	3,74	10,94	2,41	9,47	17,95	1,67*
DS	-0,69	0,92	1,15	7,77	1,02	5,94	1,69	
MZ	-0,75	0,2	0,78	7,29	0,75	5,52	0,77	
CS	-0,87	0,61	1,06	7,95	0,92	6,15	1,46	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	4,10	2,30	2,05	1,81	0,81			
DS	2,66	2,22	2,09	1,91	0,42			

KYMENLAAKSO	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,12	4,54	4,67	10,72	3,10	7,68	44,12	-0,38
DS	-1,24	2,18	2,51	22,31	2,31	15,98	12,76	
MZ	-3,14	0,55	3,18	40,67	3,14	28,78	20,49	
CS	-1,31	1,64	2,10	30,12	1,94	20,69	8,87	
Maa kuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,80	2,00	1,75	1,96	0,46			
DS	2,37	1,93	1,81	2,04	0,77			
ETELÄ-KARJALA	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-3,21	4,46	5,50	14,37	3,21	12,99	62,52	-0,33
DS	-2,83	1,88	3,40	20,93	2,83	19,15	23,9	
MZ	-1,45	0,09	1,46	16,02	1,45	13,83	4,39	
CS	-2,52	0,64	2,6	28,75	2,52	24,25	13,96	
Maa kuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,78	1,97	1,73	1,89	0,12			
DS	2,32	1,88	1,75	1,98	0,60			
ETELÄ-SAVO	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,39	2,02	2,45	11,16	1,42	8,13	24,95	0,53
DS	-0,42	1,57	1,62	10,57	0,99	6,21	10,94	
MZ	-0,83	1,50	1,72	15,10	1,13	8,77	12,23	
CS	-0,38	1,58	1,62	10,58	0,98	6,15	10,92	
Maa kuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,79	1,99	1,74	1,84	0,64			
DS	2,35	1,91	1,78	2,02	0,69			

POHJOIS-SAVO	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-0,89	1,06	1,38	6,48	0,93	4,94	9,60	-3,30*
DS	-1,27	2,11	2,46	18,43	2,04	15,7	30,41	
MZ	-2,44	0,88	2,59	22,55	2,44	19,87	33,6	
CS	-0,95	0,93	1,33	7,55	0,96	6,04	8,84	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,95	2,15	1,91	1,85	1,80			
DS	2,54	2,10	1,98	2,03	0,84			
POHJOIS-KARJALA	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-0,97	0,64	1,16	8,04	0,98	6,76	4,66	1,39
DS	-0,35	1,43	1,48	7,85	1,03	5,84	7,53	
MZ	-1,29	0,58	1,42	10,48	1,29	8,86	6,92	
CS	-0,8	0,75	1,10	7,89	0,96	6,49	4,18	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,42	1,62	1,37	1,82	1,15			
DS	1,97	1,53	1,41	1,75	1,55			
KESKI-SUOMI	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,20	1,44	1,87	12,06	1,26	9,04	1,73	0,21
DS	-0,63	1,20	1,35	13,19	1,03	10,15	0,91	
MZ	-0,94	0,88	1,29	13,09	0,96	9,93	0,82	
CS	-0,80	0,91	1,21	12,25	0,92	9,08	0,72	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,81	2,01	1,76	1,69	0,33			
DS	2,36	1,92	1,80	1,55	1,17			

ETELÄ-POHJANMAA										
	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM		
TS	-2,06	1,72	2,69	13,57	2,06	12,26	15,55	0,24		
DS	-1,64	0,83	1,84	17,36	1,64	13,95	7,26			
MZ	-1,55	0,64	1,67	21,36	1,55	16,01	6,03			
CS	-1,24	0,81	1,48	22,04	1,35	15,65	4,70			
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N					
TS	3,96	2,16	1,91	1,90	0,25					
DS	2,51	2,07	1,95	1,79	0,43					
POHJANMAA										
	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM		
TS	-1,65	3,46	3,83	6,88	1,68	5,75	23,24	1,29		
DS	-1,06	2,02	2,28	8,17	1,24	5,72	8,24			
MZ	2,11	0,72	2,23	19,25	2,11	16,19	7,85			
CS	-0,42	1,21	1,28	11,42	0,94	7,34	2,61			
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N					
TS	3,78	1,98	1,73	1,66	0,33					
DS	2,35	1,91	1,79	1,49*	0,55					
KESKI-POHJANMAA										
	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM		
TS	-0,73	1,09	1,31	5,31	0,73	4,88	3,99	1,41		
DS	0,04	0,72	0,72	4,58	0,44	3,89	1,20			
MZ	0,01	0,13	0,13	2,38	0,1	1,79	0,04			
CS	-0,22	0,25	0,33	4,54	0,23	3,62	0,25			
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N					
TS	2,92	1,12	0,88	2,25	5,57					
DS	1,47	1,03	0,91	2,09	1,58					

POHJOIS-POHJANMAA	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-0,9	1,07	1,40	6,14	0,95	5,35	2,25	2,19*
DS	0,00	1,08	1,08	4,47	0,58	3,44	1,34	
MZ	-0,43	0,58	0,72	5,10	0,54	4,10	0,59	
CS	-0,36	0,62	0,71	4,66	0,54	3,79	0,59	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	4,21	2,41	2,16	1,77	0,63			
DS	2,73	2,29	2,17	1,73	0,56			
KAINUU	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,16	1,62	1,99	6,00	1,16	4,80	1,24	-0,71
DS	-0,66	0,78	1,03	6,32	0,80	5,16	0,33	
MZ	0,11	0,34	0,36	3,22	0,30	2,62	0,04	
CS	-0,66	0,79	1,03	6,34	0,80	5,18	0,33	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,16	1,36	1,11	2,02	1,42			
DS	1,71	1,27	1,15	1,93	2,13			
LAPPI	ME	ES	RMSE	RMSPE	MAE	MAPE	U-Theil	S-DM
TS	-1,03	2,07	2,31	7,96	1,14	6,38	20,32	1,09
DS	-0,39	0,66	0,77	7,45	0,58	5,61	2,22	
MZ	-0,86	0,44	0,97	12,97	0,86	10,1	3,54	
CS	-0,23	0,57	0,62	7,64	0,51	5,66	1,46	
Maakuntamallit:	AICC	BIC	log(sig2)	DW	CHI(2)-N			
TS	3,65	1,84	1,60	1,96	0,41			
DS	2,21	1,77	1,65	1,70	0,40			

Selitykset: TS=trendistationaarinen malli, DS=differenssistationaarinen malli, MZ=Mincer-Zarnowitz -regression mukainen painotusmalli, CS=vuoden 2016 poikkileikkaukspainotusmalli, Maakuntamalli=maakunta-aineistolle rakentuva malli, ME=keskivirhe, ES=virheen hajonta, RMSE=keskineliövirheen hajonta, RMSPE=absoluuttisen %-keskineliövirheen hajonta, MAE=absoluuttinen keskivirhe, MAPE=absoluuttinen %-keskivirhe, U-Theil=Theilin testisuure, S-DM=Dieboldin ja Marianon testisuure, AICC=Akaiken informaatiokriteeri, BIC=Schwartzin informaatiokriteeri, $\log(\text{sig}^2)$ =residuaalien varianssi (log), DW= Durbin-Watson testi residuaalien aurokorrelaatiolle, CHI(2)-N=residuaalien Bera-Jarque -testi normaalisuudelle.

Kirjallisuus

- Astolfi, R., Lorenzoni L. ja Oderkirk, J. (2012), "Informing policy makers about future health spending: A comparative analysis of forecasting methods in OECD countries", *Health Policy* 107: 1–10.
- De La Maisonnette, C. and Oliveira Martins, C. (2013), "A projection method for public health and long-term care expenditures", Economics Department Working Papers No. 1048, OECD, Paris.
- Diebold, F. (2017), *Forecasting in Economics, Business, Finance and Beyond*, Edition 2017, University of Pennsylvania. <http://www.ssc.upenn.edu/~fdiebold/Teaching221/Forecasting.pdf> (viitattu 16.3.2018).
- Diebold, F. ja Mariano, R. (1995), "Comparing Predictive Accuracy", *Journal of Business and Economic Statistics* 13: 253–63.
- Fogel, R.W. (2008), "Forecasting the Cost of U.S. Health Care in 2040", NBER Working Paper No. 14361.
- Kuntaliitto (2017), "Kuntien ja kuntayhtymien tulot ja menot", Suomen Kuntaliitto 8.11.2017, <https://www.kuntaliitto.fi/asiantuntijapalvelut/talous/kuntatalouden-tilastot/kuntien-ja-kuntayhtymien-menot-ja-tulot> (viitattu 16.3.2018).
- MaCurdy, T. ja Hansen, P. (2013), "Implications of Time Series Models for Long-Term Projections of Health Expenditures", Acumen, LLC, Burlingame.
- Meklin, P. ja Pukki, H. (2017), *Kuntien sosiaali- ja terveystoimen kustannuserojen syyt, Havaintoja ARTTU2-kunnista*, ARTTU2-ohjelman tutkimuksia nro 3, Suomen Kuntaliitto.
- Nguyen, L., Häkkinen, U., Pekurinen, M., Rosenqvist, G. ja Mikkola, H. (2009), "Determinants of Health Care Expenditure in a Decentralized Health Care System", THL Discussion papers, 21/2009.
- Sheiner, L. (2014), "Perspectives on Health Care Spending Growth", Engelberg Center for Health Care Reform at Brookings.
- THL (2017a), *Terveystoiminnan menot ja rahoitus 2015*, Tilastoraportti 26/2017, Terveystoiminnan ja hyvinvoinnin laitos.
- THL (2017b), "Terveystoiminnan nettokäytökustannukset 1993–2016", *Sotkanet, Indikaattori 3268*, Terveystoiminnan ja hyvinvoinnin laitos, <https://www.sotkanet.fi/sotkanet/fi/metadata/indicators/1073> (viitattu 16.3.2018).
- Zhao, J. (2015), "Forecasting Health Expenditures: Methods and Applications to International Databases", CHEPA wp-series: 15–05. McMaster University.