

## مقایسه روش‌های مختلف پیش‌بینی رشد اقتصادی ایران با تأکید بر مدل‌های گزینشی نمودن و متوسط‌گیری الگوی پویا<sup>۱</sup>

تیمور محمدی<sup>۲</sup>

ناصر خیابانی<sup>۳</sup>

جاوید بهرامی<sup>۴</sup>

فاطمه فهیمی‌فر<sup>۵</sup>

تاریخ پذیرش: ۱۳۹۸/۱۱/۱۲

تاریخ دریافت: ۱۳۹۸/۸/۱۹

### چکیده

در دهه‌های اخیر، به دلیل اهمیت مقادیر آتی متغیرهای کلان اقتصادی، طیف وسیعی از روش‌ها و مدل‌های پیش‌بینی، مورد بررسی و ارزیابی قرار گرفته است. هدف اصلی این مقاله، مقایسه روش‌های مختلف پیش‌بینی رشد اقتصادی ایران با استفاده از داده‌های سری زمانی فصلی در دوره زمانی ۹۶-۱۳۶۹ است. به منظور دستیابی به این هدف، به پیش‌بینی این متغیر با استفاده از مدل‌های  $AR$  و  $TVP$ ،  $BVAR$ ،  $BMA$ ،  $DMS$ ،  $DMA$  در سه افق پیش‌بینی (یک، چهار و هشت فصل) پرداخته شده است. مدل‌های مورد استفاده در این مطالعه، به سه طیف، بزرگ مقیاس (شامل ۱۱۲ متغیر در نه بلوک عاملی)، متوسط مقیاس (شامل ۱۰ متغیر) و مدل‌های تک متغیره، دسته‌بندی شده‌اند. نتایج مطالعه، نشان می‌دهد که پیش‌بینی مدل‌های گزینشی نمودن ( $DMS$ ) و متوسط‌گیری الگوی پویا ( $DMA$ ) نسبت به سایر روش‌های پیش‌بینی سنتی، دارای عملکرد پیش‌بینی بسیار کارآیی برای رشد اقتصادی ایران هستند.

واژگان کلیدی: پیش‌بینی، رشد اقتصادی، مدل فضا-حالت، مدل عاملی، متوسط‌گیری الگوی پویا  
طبقه‌بندی JEL: C32, C38, C53, E37, O47

۱. مقاله حاضر، مستخرج از رساله دکتری در دانشگاه علامه طباطبائی است.

۲. دانشیار و عضو هیأت علمی دانشکده اقتصاد، دانشگاه علامه طباطبائی (نویسنده مسؤول)

mohammadi@atu.ac.ir

naser.khiabani@atu.ac.ir

۳. دانشیار و عضو هیأت علمی دانشکده اقتصاد، دانشگاه علامه طباطبائی

javid\_bahrami@yahoo.com

۴. دانشیار و عضو هیأت علمی دانشکده اقتصاد، دانشگاه علامه طباطبائی

fatemehfahimifar@gmail.com

۵. دانشجوی دکتری اقتصاد، دانشگاه علامه طباطبائی

## ۱. مقدمه

بررسی و پیش‌بینی متغیرهای اقتصاد کلان برای بخش‌های دولتی و خصوصی، از اهمیت زیادی برخوردار است. پیش‌بینی متغیرهای کلان از یک‌سو، به سیاست‌گذاری و برنامه‌ریزی اقتصادی بخش دولتی منجر می‌شود (Holden *et al.*, 1999). از سوی دیگر نتایج سیاست‌گذاری، به ثبات اقتصاد کلان و تأثیر بر تصمیمات بخش خصوصی (تمایل بنگاه‌های اقتصادی برای سرمایه‌گذاری و تمایل خانوارها برای پیش‌بینی درآمدهای آتی) منتهی می‌گردد (Carnot *et al.*, 2005).

متغیرهای اقتصاد کلان مانند رشد اقتصادی، تورم، قیمت انرژی، اشتغال و بیکاری، سرمایه‌گذاری و نرخ ارز، برای برنامه‌ریزی اقتصادی دولت و رفاه جامعه اهمیت دارد. با توجه به اینکه یکی از اهداف مهم اقتصاد کلان، رشد اقتصادی پایدار و فراگیر است، لذا پیش‌بینی مهم‌ترین متغیر اقتصادی یعنی رشد اقتصادی برای بانک مرکزی و دولت و نیز بخش خصوصی دارای نقش مهمی است. یکی از مسائلی که در بسیاری از کشورها مطرح است، تجدیدنظر و زمان انتشار آمار تولید ناخالص داخلی است که این موضوع، به بروز مشکلاتی در سیاست‌گذاری‌های بخش دولتی و کارگزاران اقتصادی بخش خصوصی منجر گردیده، و به همین دلیل، پیش‌بینی این متغیر برای هر کشوری از اهمیت بسزایی برخوردار شده است (Barsoum & Stankiewicz, 2013).

لذا روش‌های پیش‌بینی متغیرهای اقتصاد کلان، به سرعت در حال تکامل هستند و حتی به عنوان یک شاخه پژوهشی نیز مطرح شده است. در حال حاضر، محققان در حوزه کلان، با داده یا داده‌های حجیم<sup>۱</sup> با روش‌های برآزش بسیار پیچیده، به دنبال دستیابی به بهترین روش پیش‌بینی هستند (Saleille, 2015). در عین حال، نهادهای منتشرکننده آمار متغیرهای اقتصادی (مانند وزارت اقتصاد و بانک مرکزی) در کشورهای مختلف جهان و حتی سازمان‌های بین‌المللی (صندوق بین‌المللی پول و بانک جهانی) نیز به منظور پیش‌بینی شاخص‌های اقتصادی، مدل‌های پیش‌بینی را به طور منظم، مورد بررسی و ارزیابی قرار می‌دهند.

در مطالعات مربوط به پیش‌بینی متغیرهای اقتصادی، اقتصاددانان با دشواری‌های مختلفی از جمله مسأله ابعاد آموچه هستند. به عنوان مثال، برای پیش‌بینی متغیر رشد اقتصادی، ممکن است مجموعه بسیار بزرگی از متغیرهای پیش‌بینی کننده مطرح باشند. به عبارتی دیگر، برای دستیابی به پیش‌بینی آتی یک متغیر، امکان دارد، متغیرهای بسیاری از جمله اسمی، حقیقی و حتی متغیرهای محیط بین‌المللی بر آن اثرگذار باشند. همچنین، وجود داده‌های با تواترهای زمانی مختلف و بلندمدت نیز یک مشکل جدی است. تنها تعداد محدودی از متغیرهای کلان اقتصادی، سری‌های زمانی مناسبی

1. Big Data
2. Curse of Dimensionality

برای پیش‌بینی دارند. لذا وفور پارامترها، یک نگرانی جدی در مدل‌های پیش‌بینی، بویژه برای اقتصاد ایران (که با محدودیت آماری مواجه است) می‌باشد. به عبارتی دیگر، وفور پارامتر در شرایطی که تعداد مشاهدات زیاد نباشد، باعث انحراف در مدل پیش‌بینی می‌شود.

روش‌های مختلفی برای رفع مشکلات مسأله ابعاد مربوط به پیش‌بینی متغیرهای اقتصادی در مطالعات، ارائه شده است. اما باید به دنبال مدلی بود که تعداد پارامترها را کاهش دهد. از مهم‌ترین این مدل‌ها، مدل‌های عاملی پویا (DFMs) و مدل متوسط‌گیری پویا<sup>۳</sup> (DMA) است. در سال‌های اخیر، مدل‌های مذکور به طور گسترده‌ای مورد توجه اقتصاددانان بویژه در حوزه اقتصادسنجی قرار گرفته است. مدل‌های عاملی پویا (DFMs) در ابتدا توسط جِوِک (Geweke, 1977) مطرح گردید. این مدل‌ها به منظور کوچک کردن اطلاعات ارائه شده با یک مجموعه بزرگی از متغیرهای پیش‌بینی‌کننده، به عوامل متعامل کمتری تبدیل، و از طریق تحلیل مؤلفه‌های اساسی، برآورد شده‌اند. دی مول و همکاران (De Mol et al., 2008) و بنبورا و همکاران (Banbura et al., 2010) ثابت کردند، روش انقباضی بی‌زین‌آبرای تخمین VARهای بزرگ مقیاس سودمند است. زمانی که پدیده‌ها در طول دوره‌های طولانی مدت، مدل‌سازی می‌شوند، به احتمال زیاد، پارامترها به‌طور قابل ملاحظه‌ای تغییر می‌کنند. به این دلیل، محققان جهت پیش‌بینی، تلاش‌های بسیاری را به منظور لحاظ دادن شکست‌های ساختاری در این مدل‌های آماری انجام داده‌اند. در این راستا، یک روش مناسب، مدل پارامتر متغیر در طول زمان VAR (TVP-VAR) می‌باشد.


یکی دیگر از موضوعات بحث برانگیز در آمار مدرن، معرفی نااطمینانی نه تنها در فضای پارامتری، بلکه در فضای مدلی است (Varian, 2014). در این راستا، کوپ و کورویلیس (Koop & Korobilis, 2012) الگوی متوسط‌گیری پویا (DMA) را مطرح نموده‌اند (Bork & Moller, 2015; Saleille, 2015). اما به طور کلی مزیت اصلی<sup>۴</sup> DMA/DMS در مدل‌سازی آن است که این مدل‌ها، نه تنها اجازه می‌دهند، ضرایب یک متغیر در طول زمان تغییر کنند، بلکه مجموعه متغیرها نیز در طول زمان تغییر می‌کند.

یکی از مشکلات ساختاری اقتصاد ایران، رشد اقتصادی ناپایدار و نامستمر همراه با نوسان‌های متعدد است. این موضوع باعث شده که دشواری‌هایی برای پیش‌بینی رشد اقتصادی کشور ایجاد شود. متوسط رشد اقتصادی کشور در دوره ۱۳۹۶:۴-۱۳۶۹:۱، برابر با ۴٫۲ درصد و انحراف معیار آن، برابر با ۷ بوده است که این موضوع، گویای تلاطم‌های بالای این متغیر مهم اقتصادی در کشور است که

1. Over Parametrization
2. Dynamic Model Averaging
3. Bayesian shrinkage
4. Dynamic Model Selection

عمده دلیل آن، به‌واسطه نوسانات درآمدهای نفتی می‌باشد. درآمدهای ناشی از صادرات نفت، از طریق واردات کالاهای سرمایه‌ای و واسطه‌ای، به افزایش تولید و به تبع آن، افزایش رشد اقتصادی منجر می‌شود.

از سوی دیگر، از طریق واردات کالاهای مصرفی، تولید داخلی، تضعیف، و رشد اقتصادی کاهش می‌یابد. علاوه بر این، کاهش درآمدهای نفتی، به کاهش هزینه‌های عمرانی دولت منجر شده و در نتیجه، کاهش رشد اقتصادی را به همراه خواهد داشت. بنابراین، این نوسانات در رشد اقتصادی که به دلیل نوسانات درآمدهای نفتی ایجاد می‌شود، پیش‌بینی رشد اقتصادی کشور را دشوار می‌سازد.



نمودار ۱. نرخ رشد اقتصادی ایران در طول سال‌های ۱۳۶۹:۱-۱۳۹۶:۴ (درصد)

مأخذ: بانک مرکزی ج.ا.ا.

از این رو این، مقاله به دنبال انتخاب مدلی از بین مدل‌های مختلف پیش‌بینی است که بتواند پیش‌بینی دقیقی از رشد اقتصادی در ایران را ارائه دهد.

## ۲. ادبیات موضوع

مدل‌های استاندارد در مقیاس کوچک شامل مدل‌های تک متغیره، مدل‌های VAR با مرتبه کم و مدل‌های رگرسیون ساده برای پیش‌بینی کوتاه‌مدت متغیرهای اقتصاد کلان به کار می‌روند. سیمز (Sims, 1980) مدل VAR خطی را برای پیش‌بینی متغیرهای اقتصاد کلان آمریکا پیشنهاد داده بود. اگر چه این رویکرد در ابتدا، نتایج قابل قبولی را ارائه نمود، اما نقطه ضعف اصلی مدل‌های VAR، مشکل وفور پارامترها با تعداد زیادی از پارامترهای غیرمعنادار بود؛ به طوری که مشکل وفور پارامترها

باعث می‌شود، مدل‌های VAR غیرمقید، حتی با داشتن برازش داخل نمونه‌ای خوب، پیش‌بینی‌های خارج از نمونه‌ای بسیار ضعیفی را داشته باشند. به منظور مقابله با این مشکلات، لیترمن (Litterman, 1986)، یک تکنیک جدید به نام اتورگرسیو برداری بیزین (BVAR) را با هدف کاهش پارامترهای VAR مطرح نمود که این تکنیک، مشکل بیش برازشی را برطرف نمود.

روش دیگر، مدل VECM انگل و گرنجر (Engle & Granger, 1987) است که رابطه بلندمدت میان متغیرهای کلان اقتصادی را در تحلیل‌های اقتصادی مورد استفاده قرار می‌دهد. آنها با استفاده از داده‌های کلان اقتصادی کشور آمریکا، به این نتیجه رسیدند که متغیرهای تولید ناخالص ملی اسمی و نقدینگی، هم‌انباشته هستند.

انگل و یو (Engle & Yoo, 1987)، به پیش‌بینی رفتار متغیرهای هم‌انباشته پرداختند. آنها استدلال نمودند که برآوردهای دو مرحله‌ای انگل و گرنجر (Engle & Granger, 1987)، می‌توانند با مدل ساختاری تصحیح خطا به کار روند. در نتیجه از این طریق، مزایای پیش‌بینی چند مرحله‌ای به دست می‌آید.

گوپتا (Gupta, 2006)، با استفاده از داده‌های کشور آفریقای جنوبی، به پیش‌بینی تعدادی از متغیرهای کلیدی کلان اقتصادی از جمله GDP، مصرف، سرمایه‌گذاری، نرخ‌های بهره کوتاه‌مدت و بلندمدت و شاخص قیمت مصرف‌کننده پرداخت و به این نتیجه رسید که پیش‌بینی‌های خارج از نمونه‌ای مدل<sup>۱</sup> BVECM عملکرد بهتری نسبت به مدل‌های VAR و VECM کلاسیک دارند.

مطالعات بسیاری با استفاده از رویکرد غیرخطی، متغیر تولید ناخالص داخلی را مورد بررسی قرار داده‌اند. هدف از این مطالعات، بررسی توانایی مدل‌های غیرخطی مانند مارکف سوئیچینگ (Hamilton, 1989) و مدل‌های SETAR<sup>۲</sup> (Clements & Smith, 1997)، جهت ارائه پیش‌بینی متغیرهای اقتصادی از جمله رشد اقتصادی بوده است. به عنوان نمونه، کلمنتس و کروزلیگ (Clements & Krolzig, 1998)، عملکرد مدل‌های MS و ESTAR را در دوره پس از جنگ جهانی دوم برای متغیر تولید ناخالص ملی کشور آمریکا، مورد مقایسه قرار دادند. نتایج مطالعه آنها نشان داد که اگرچه هر دو مدل مذکور، ویژگی‌های ادوار تجاری خاص را در نظر گرفتند و حتی این مدل‌ها نسبت به مدل‌های خطی برتری داشتند، اما توانایی پیش‌بینی با دقت بالاتری نسبت به مدل‌های رقیب را نداشتند.

بخشی از ادبیات اقتصادی در دهه‌های اخیر، میزان اطلاعات لازم برای دستیابی به برآورد قوی از پیش‌بینی تولید ناخالص داخلی را مورد بررسی قرار دادند (Marcellino *et al.*, 2003; Bernanke & Boivin, 2003; Forni *et al.*, 2009; Boivin, & Ng, 2006; D'Agostino, &

1. Bayesian Vector Error Correction (BVECM)

2. Self-Exciting Threshold Autoregressive (SETAR) models

(Giannone, 2012) از جمله دستاوردهای مهم در این خصوص، استفاده از روش‌های مختلف اقتصادسنجی برای به‌کارگیری اطلاعات داده‌های حجیم (کلان داده) برای پیش‌بینی بود. در چنین رویکردی، مدل‌های عاملی، بیشتر مورد توجه بوده و استفاده از آنها بسیار رایج شده است. مدل‌های عاملی، اطلاعات را از یک مجموعه حجیمی (کلان داده) از شاخص‌ها در تعداد کمی از مؤلفه‌های اساسی غیرقابل مشاهده خلاصه می‌کنند.

مطالعات استاک و واتسون (Stock & Watson, 1998 & 2002) برای کشور آمریکا؛ فورنی و همکاران (Forni et al., 2000 & 2003)، مارسلینو و همکاران (Marcellino et al., 2003) و آنجلینی و همکاران (Angelini et al., 2010)، برای منطقه یورو، آرتیس و همکاران (Artis et al., 2007) برای کشور انگلیس و شوماخر (Schumacher, 2007) برای کشور آلمان، نمونه‌هایی از مطالعات تجربی با استفاده از مدل‌های عاملی هستند.

استخراج اطلاعات از داده‌های حجیم (کلان داده) می‌تواند در بهبود فرایند پیش‌بینی، کمک بسزایی کند؛ در حالی که نتایج اولیه حاصل از پیش‌بینی در مطالعات تجربی در این خصوص، بسیار امیدوارکننده بوده است (Stock & Watson, 2002; Forni et al., 2000; Naser, 2014)؛ که می‌توان به مطالعه، استاک و واتسون (Stock & Watson, 2006) که با به‌کارگیری بیش از ۲۱۵ متغیر، به پیش‌بینی متغیرهای کلان کشور آمریکا پرداختند، اشاره نمود.

علاوه بر این، مدل‌های پارامتر متغیر در طول زمان (TVP)، روش‌های فضا حالت (مانند فیلتر کالمن) را به‌کار می‌گیرند که این موضوع، عموماً در تحقیقات تجربی اقتصاد کلان در راستای تجزیه و تحلیل ساختاری و پیش‌بینی استفاده می‌شود. چنانچه مجموعه بزرگی از داده‌ها به منظور پیش‌بینی متغیرهای کلان اقتصادی استفاده گردد، مدل‌های TVP تمایل به بیش‌برازشی<sup>۱</sup> در داخل نمونه دارند، لذا عملکرد پیش‌بینی ضعیفی در خارج از نمونه خواهند داشت.

برای تصحیح این کاستی‌ها در مدل‌های TVP، از مدل‌های DMA و DMS استفاده شده است (Guptta et al., 2014). به منظور بررسی مدل‌های DMA و DMS، ابتدا مدل عاملی پویای بلوکی با ضرایب زمان متغیر در فرم فضا حالت استاندارد را در نظر بگیرد:

$$y_t = Z_t \theta_t + \varepsilon_t \quad (1)$$

$$\theta_{t+1} = \theta_t + \eta_t, \quad (2)$$

به طوری که معادله (۱)، معادله اندازه‌گیری و معادله (۲)، معادله وضعیت می‌باشند.  $y_t$  متغیر وابسته پیش‌بینی است،  $Z_t$  یک بردار  $1 \times m$  از مشاهدات متغیرهای توضیحی (متغیرهای پیش‌بینی کننده) است که برای پیش‌بینی  $y_t$  مورد استفاده قرار می‌گیرند.

## 1. Over-Fit

زمانی که یک دوره جلوتر را پیش‌بینی می‌کنیم ( $h=1$ )،  $Z_t$  شامل یک عرض از مبدأ،  $y_{t-1}, \dots, y_{t-p_y}, f_{t-1}^{(b)}, \dots, f_{t-p_f}^{(b)}$  (for  $b=1, \dots, B$ ) می‌شود؛ به طوری که  $p_y$  طول وقفه متغیر وابسته و  $p_f$  طول وقفه برای فاکتورها است. زمانی که پیش‌بینی برای  $h > 1$  دوره جلوتر باشد، از روش مستقیم استفاده می‌کنیم و متغیرها به طور مناسبی با وقفه می‌شوند (به عنوان مثال،  $Z_t$  شامل اطلاعات تأخیری  $h$  دوره است).  $f_t^{(b)}$  با استفاده از روش مؤلفه‌های اساسی<sup>۱</sup> دربرگیرنده تمام متغیرهای بلوک  $b$ ، ساخته می‌شود.<sup>۲</sup> بنابراین، تمام مؤلفه‌های  $Z_t$  می‌توانند به عنوان متغیرهای وابسته برونزا یا تأخیری تفسیر شوند.  $\theta_t$  یک بردار  $m \times 1$  از ضرایب رگرسیون است،  $\varepsilon_t \sim N(0, H_t)$  است و  $\eta_t \sim N(0, Q_t)$  است که  $H_t$  و  $Q_t$  به ترتیب، ماتریس واریانس و کوواریانس معادله اندازه‌گیری و وضعیت هستند. این مدل یک مدل فضا حالت معمولی است که در اقتصاد کلان تجربی استفاده می‌شود (Cogley & Sargent, 2005; Cogley et al., 2005; Primiceri, 2005).

روش‌های استاندارد مانند فیلتر کالمن، باعث می‌شود که برازش و پیش‌بینی با چنین مدلی بدون مشکل انجام گیرد. با این حال، در معادله (۱) و (۲) فرض می‌شود که متغیرهای توضیحی یکسانی برای پیش‌بینی در تمام نقاط زمان استفاده شده است. علاوه بر این، مدلی مانند معادله (۱) و (۲) که همان مجموعه متغیرهای پیش‌بینی‌کننده را در تمام دوره‌های زمانی حفظ می‌کنند، به دلیل مشکل وفور پارامتری، از عملکرد پیش‌بینی ضعیفی برخوردار می‌باشند.  
بر این اساس، برای  $K$  مدل:

$$y_t = Z_t^{(k)} \theta_t^{(k)} + \varepsilon_t^{(k)} \quad (3)$$

$$\theta_{t+1}^{(k)} = \theta_t^{(k)} + \eta_t^{(k)}, \quad (4)$$

که در آن،  $\varepsilon_t^{(k)} \sim N(0, H_t^{(k)})$  و  $\eta_t^{(k)} \sim N(0, Q_t^{(k)})$ ،  $L_t$  شاخصی از مدل، و  $L_t = k$  به معنی آن می‌باشد که مدل  $k$  انتخاب شده است. در DMA، وزن‌های استفاده شده در روش مدل میانگین‌گیری در طول زمان می‌توانند تغییر کنند و در DMS، مدل انتخاب شده در طول زمان می‌تواند تغییر کند. DMA و DMS با محاسبه  $\Pr(L_t = k | Y^{t-1})$  برای  $k = 1, \dots, K$ ، به طوری که

۱. در کاربرد پیش‌بینی بازگشتی، عوامل را به طور بازگشتی استخراج کردیم؛ به طوری که عوامل در زمان  $\tau$  با استفاده از اطلاعات زمان  $\tau$  ساخته شده‌اند.

۲. شق دیگر برای  $f_t^{(b)}$  به عنوان یک متغیر پنهان خواهد بود و آن در چارچوبی از الگوریتم زنجیره مارکف مونت کارلو توسط انگ و همکاران (Ng et al., 2008) شبیه‌سازی شده است. این موضوع از منظر نظری آسان است، اما زمان انجام DMA با تعداد مناسبی از بلوک‌ها غیرقابل محاسبه است.

$Y^{t-1} = \{y_1, \dots, y_{t-1}\}$  است، قابل اجرا می‌باشند (محاسبه احتمال اینکه مدل  $k$  باید برای پیش‌بینی  $y_t$  با استفاده از اطلاعات زمان  $t-1$  استفاده شود).  
 احتمالات این چارچوب به صورت  $\pi_{t|t-1,k} = \Pr(L_t = k | Y^{t-1})$  نشان داده می‌شود. ایده مرتبط با DMS، انتخاب مدلی با بالاترین احتمال  $(\pi_{t|t-1,k})$  در هر دوره زمانی است، در حالی که DMA احتمالات  $\pi_{t|t-1,k}$  for  $k = 1, \dots, K$  را به عنوان وزن‌های مدل برای محاسبه میانگینی از  $K$  پیش‌بینی استفاده می‌کند<sup>۱</sup>.

ممکن است، بسیاری از مدل‌ها تعداد زیادی پارامتر داشته باشند؛ و زمانی که  $k$  مدل برازش می‌شود، مدت زمان زیادی جهت حصول نتایج نیاز داشته باشد. بنابراین، رویکرد بیزین کامل برای DMA بسیار مشکل می‌شود. از این رو، به منظور ممانعت از این مشکل، مطابق مقاله کوپ و کوروبیلیس (Koop & Korobilis, 2012) از تقریب‌های رافتری و همکاران (Raftery et al., 2007) استفاده می‌گردد. این تقریب‌ها شامل دو پارامتر  $\lambda$  و  $\alpha$  هستند که رافتری و همکاران (Raftery et al., 2007) به آنها "عامل فراموش شده" می‌گویند. عامل فراموش شده  $\lambda$  در معادله وضعیت برای پارامترها و عامل فراموش شده  $\alpha$  در معادله وضعیت برای مدل‌ها استفاده شده است. یک جنبه از الگوریتم رافتری و همکاران (Raftery et al., 2007) عدم نیاز به استفاده از زنجیره مارکف مونت کارلو (MCMC) در هر مدل انفرادی است. آنها این کار را برای به‌دست آوردن تخمین جایگزینی<sup>۲</sup> از  $H_t$  و فرض  $Q_t = (1 - \lambda^{-1}) \Sigma_{t-1}$  انجام می‌دهند، به طوری که  $0 < \lambda \leq 1$  و  $\Sigma_t$  ماتریس کوواریانس خطای تخمین در فیلتر کالمن است. به طور کلی، می‌توان  $\pi_{t|t-1,k}$  را در یک روش تکرارشونده به‌دست آورد و بنابراین:

$$\pi_{t-1|t-1,k} = \frac{\pi_{t-1|t-2,k} p_k(y_{t-1} | y^{t-2})}{\sum_{s=1}^K \pi_{t-1|t-2,s} p_s(y_{t-1} | y^{t-2})} \quad (5)$$

به طوری که  $p_s(y_{t-1} | y^{t-2})$  چگالی پیش‌بینی‌کننده برای مدل  $s$  در  $y_{t-1}$  است. از سوی دیگر داریم:

<sup>۱</sup> رافتری و همکاران (Raftery et al., 2010) بر DMA در یک برنامه صنعتی تمرکز کردند، در حالی که کوپ و کوروبیلیس (Koop & Korobilis, 2012) هر دوی روش‌های DMA و DMS را برای پیش‌بینی تورم استفاده نموده‌اند.

2. Forgetting Factor
3. Plug-In



$$\pi_{t|t-1,k}^{\alpha} = \frac{\pi_{t-1|t-1,k}^{\alpha}}{\sum_{l=1}^K \pi_{t-1|t-1,l}^{\alpha}} \quad (۶)$$

به طوری که  $0 < \alpha \leq 1$  یکی دیگر از عوامل فراموش شده است که تفسیر آن مشابه  $\lambda$  بوده، اما در آن به جای تکامل پارامترها، تکامل مدل‌ها مطرح است.

زمانی که داده‌ها در فرکانس نسبتاً بالا هستند، می‌توان انتظار داشت که پارامترها و متغیرهای پیش‌بینی‌کننده، به طور نسبی مکرراً تغییر یابند. این موضوع، به معنی آن است که مقادیر تنظیم‌کننده  $\alpha, \lambda$  نزدیک به ۱ ممکن است، پیش‌بینی‌های بهینه‌ای نداشته باشند و بنابراین، با استفاده از مجموعه‌ای از مقادیر  $\alpha, \lambda$  در یک نمونه از آموزش‌های اولیه، پیش‌بینی صورت می‌گیرد و سپس مقادیر ترکیبی بهینه انتخاب می‌شوند که برخی از آنها، عملکرد معیار آماری را به حداقل می‌رساند (Koop & Korobilis, 2011; Bork & Møller, 2014; Belmonte & Koop, 2014; Aye et al., 2015).

### ۳. مروری بر مطالعات تجربی

کوپ و کوروبیلیس (Koop & Korobilis, 2011) در مقاله‌ای، به پیش‌بینی متغیرهای رشد اقتصادی و تورم انگلستان بر اساس مدل‌های مختلف پیش‌بینی پرداخته و در نهایت، آنها را مورد مقایسه قرار دادند. آنها از ۱۳۹ متغیر برای دوره ماه ژانویه سال ۱۹۹۰ تا ماه نوامبر سال ۲۰۰۸ در قالب ۸ بلوک شامل، بلوک تجارت خارجی (بخش بین‌المللی)، بلوک ستاده، بلوک قیمتی، بلوک تقاضا، بلوک مالی، بلوک مسکن، بلوک پول و بلوک نیروی کار و مدل‌های *TVP-AR-X-DMA*، *TVP-AR-X-DMS*، *TVP-AR-X-BMA*، *UC-SV*، *FAVAR* به منظور پیش‌بینی متغیرهای رشد اقتصادی و تورم پرداختند.

جهت محاسبه کارایی پیش‌بینی‌ها، مربع میانگین خطای پیش‌بینی<sup>۲</sup> (MSFE) و قدرمطلق میانگین خطای پیش‌بینی<sup>۳</sup> (MAFE) به کار گرفته شده است. نتایج مطالعه آنها، نشان داد که مدل‌های *DMA* و *DMS*، تا حد زیادی عملکرد پیش‌بینی را نسبت به روش‌های سنتی بهبود می‌بخشد.

کوپ (Koop, 2012) در مقاله‌ای با استفاده از ۲۵ متغیر اقتصاد کلان کشور آمریکا، به بررسی پیش‌بینی تورم، تولید ناخالص داخلی و نرخ بهره برای دوره فصل اول ۱۹۵۹ تا فصل دوم سال ۲۰۱۰ پرداخت. در مطالعه آنها، به منظور پیش‌بینی متغیرهای کلان، از مدل‌های *TVP-VAR-DMS*،

۱. به عنوان مثال، در مقاله کوپ و کوروبیلیس (Koop & Korobilis, 2009)، مقدار پیش فرض  $\alpha = \lambda = 0.99$  برای داده‌های کلان فصلی، پیشنهاد شده است.

2. Mean Squared Forecast Error  
3. Mean Absolute Forecast Error

$VAR$ ،  $TVP-VAR$ ،  $Random Walk$  استفاده شده، همچنین برای مقایسه کارآیی پیش‌بینی، از مربع میانگین خطای پیش‌بینی (MSFE) و لاکلیه‌دهای پیش‌بینی<sup>۱</sup> بهره‌گیری به عمل آمده است. نتایج، نشان می‌دهد که رویکرد  $TVP-VAR-DMS$  نسبت به سایر رویکردهای پیش‌بینی، بهتر می‌باشد. این موضوع به‌خصوص در نرخ تورم و تولید ناخالص داخلی، بیشتر قابل مشاهده، و در رابطه با نرخ بهره، پیش‌بینی  $TVP-VAR-DMS$  در برخی از افق‌های پیش‌بینی دقیق‌تر، اما در برخی دیگر افق‌ها، رویکرد  $TVP-VAR$ ، دارای عملکرد بهتری بوده، و با این حال، MSFE نشان داد که رویکرد  $TVP-VAR-DMS$ ، بهترین پیش‌بینی کننده در میان رویکردهای دیگر است.

نیکولتی و پاسارو (Nicoletti & Passaro, 2012) در مقاله‌ای، به پیش‌بینی رشد تولید ناخالص داخلی ایتالیا پرداخته‌اند. برخی از متغیرهای کنترل این مقاله، مشابه متغیرهای مطالعه استاک و واتسون (Stock & Watson, 2003) می‌باشد. در این مقاله، برای اجرای مدل DMA از ۳۴ شاخص و حداقل ۲۳۴ مدل استفاده شده است. برای پیش‌بینی از افق‌های ۱ و ۴ فصل آینده و برای بررسی عملکرد پیش‌بینی، از معیار MSFE استفاده شده است. در این مقاله، از  $\alpha = 0.9, 0.95, 0.99$  و  $\lambda = 0.9, 0.95, 0.99, 1$  در مدل‌ها بهره گرفته شده است.

سالیله (Saleille, 2015) در پژوهشی، به پیش‌بینی تولید ناخالص داخلی فرانسه پرداخته است. از نرخ رشد تولید ناخالص داخلی به صورت فصلی، به عنوان متغیر وابسته، استفاده شده است. مجموعه داده‌های این پژوهش شامل ۲۸۵ مشاهده ماهانه برای ۵۱ شاخص از فوریه ۱۹۹۱ تا اکتبر ۲۰۱۴ می‌باشد. در این مطالعه، از مدل‌های گام تصادفی،  $AR(p)$ ،  $DFM$ ،  $DMA$ ،  $DMS$  برای پیش‌بینی، استفاده شده است. آنها به منظور بررسی عملکرد پیش‌بینی، از RMSE جهت ۸ افق زمانی (پیش‌بینی از ۱ تا ۸ ماه) استفاده نمودند. نتایج مطالعه آنها، نشان داد که مدل  $AR(p)$  کمی بهتر از گام تصادفی ساده است، بویژه زمانی که پیش‌بینی با افق زمانی طولانی‌تری باشد.

پیش‌بینی‌های  $DFM$  بهتر از  $AR(p)$  در تمام افق‌های پیش‌بینی بوده است. این موضوع، نشان می‌دهد که متغیرهای پیش‌بینی‌کننده کوتاه‌مدت، اطلاعات فراوانی را در فرایند پیش‌بینی اضافه می‌کنند.  $DMS$  و  $DMA$  عملکرد بهتری نسبت به  $DFM$  داشته‌اند. آنها بیان کردند که  $DMA$  و  $DMS$  برای پیش‌بینی تولید ناخالص داخلی کشور فرانسه، بهترین گزینه می‌باشد (حداقل در میان موارد مورد آزمون آنها).

اونورانت و رافتری (Onorante & Raftery, 2016) در مقاله‌ای، به پیش‌بینی تولید ناخالص داخلی در منطقه یورو در دوره فصل اول سال ۲۰۰۳ تا فصل اول ۲۰۱۴ پرداختند. آنها بیان نمودند که در زمانی که مدل به صورت بزرگ‌مقیاس باشد، مدل  $DMA$  اولیه قابل اجرا نمی‌باشد و به همین

## 1. Predictive Likelihoods

علت، در این مقاله، روش (DMA) براساس پنجره اوکام<sup>۱</sup> *Dynamic Occam's Window (DOW)* مورد بررسی قرار گرفته، مدل‌های به کار برده شده در این مقاله، عبارت از *Random Walk*،  $AR(2)$ ،  $DMA^2$ ،  $DMAE^3$ ،  $DMSR$  و  $DMS-E$  بوده، و همچنین به منظور محاسبه کارآیی پیش‌بینی، از  $MAX^4$  و  $MAE^5$ ،  $RMSE$  استفاده شده است.

خضری و همکاران (۲۰۱۹) در مقاله‌ای، به پیش‌بینی نرخ تورم ایران با استفاده از داده‌های فصلی در دوره زمانی ۹۱-۱۳۶۷ پرداخته‌اند. آنها در این مطالعه، از مدل‌های *DMS*، *DMA*، *TVP-BMA*، *BMA* و *TVP*، استفاده نمودند. همچنین به منظور بررسی کارآیی عملکرد پیش‌بینی، از *MSFE* و *MAFE* بهره گرفته و در نهایت، به این نتیجه رسیده‌اند که قدرت پیش‌بینی مدل‌های پویا از سایر مدل‌های به کار گرفته شده، بیشتر است.

بیانی و محمدی (۱۳۹۸) در مقاله‌ای، عوامل مؤثر بر بحران‌های مالی با رویکرد میانگین‌گیری بیزی (*BMA*) را بررسی نموده‌اند. در مقاله حاضر، از ۶۲ متغیر مؤثر بر بحران مالی استفاده شده و در نهایت، با استفاده از رویکرد مدل میانگین‌گیری بیزی، ۱۲ متغیر غیرشکننده مؤثر بر بحران مالی شناسایی شده‌اند. نتایج مطالعه آنها، نشان داد که به علت تأثیرپذیری از متغیرهای مرتبط با سیاست مالی، سیاست پولی و سیاست ارزی، شاخص بحران مالی در اقتصاد ایران، چند بعدی است.

خدایی و همکاران (۱۳۹۷) در مطالعه‌ای، اثر سیاست‌های مالی بر رشد اقتصادی ایران با استفاده از داده‌های فصلی سال‌های ۱۳۶۷ تا ۱۳۹۵ و همین‌طور مدل‌های خودرگرسیون برداری عاملی (*FAVAR*) در ترکیب با روش‌های پارامترهای متغیر در طول زمان (*TVP*)، مورد بررسی قرار دادند. نتایج این مطالعه، بیانگر آن است که سیاست‌های مالی بر رشد اقتصادی ایران در کل دوره مورد بررسی، دارای اثرگذاری مثبت بوده و با افزایش سرمایه‌گذاری در کشور، نرخ رشد اقتصادی نیز با افزایش روبرو می‌شود.

مهرآرا و همکاران (۱۳۹۵) در مقاله‌ای، با استفاده از روش اقتصادسنجی متوسط‌گیری بیزی (*BMA*)، رابطه بین ۱۶ متغیر مؤثر بر رشد اقتصادی ایران در سال‌های ۹۳-۱۳۴۰ را مورد بررسی قرار دادند. نتایج مطالعه آنها، بیانگر آن است که به ترتیب، متغیرهای نسبت سرمایه‌گذاری به تولید،

1. Occam's Window
2. Reduced DMA Method
3. Expanded DMA Method
4. Maximum Absolute Error
5. Mean Absolute Error
6. Root Mean Squared Error

نرخ رشد جمعیت، رشد واردات کالاهای سرمایه‌ای، رشد نیروی کار و رشد واردات کالاهای واسطه‌ای، دارای بالاترین احتمال شمول بوده‌اند.

حیدری و سلماسی (۱۳۹۴) در مقاله‌ای، به بررسی عملکرد مدل‌های مختلف خودرگرسیون برداری بیزی جهت پیش‌بینی متغیرهای رشد تولید ناخالص داخلی، تورم، نقدینگی، نرخ بهره و نرخ ارز حقیقی برای ۴ دوره ایران پرداخته‌اند. آنها از دو مدل BVAR Normal و BVAR با الگوریتم گیس و با توزیع پیشین‌های مختلف بی‌اطلاعی، مینسوتا و مزدوج طبیعی و نرمال ویشارد استفاده کرده‌اند. نتایج، بیانگر آن است که مدل با تابع پیشین مینسوتا، دارای عملکرد بهتری نسبت به مدل‌های شبه بیزی داشته است.

آرمن و ایزدی (۱۳۹۲) در مقاله‌ای، به پیش‌بینی رشد اقتصادی ایران و مقایسه آن با مدل‌های سری زمانی تک متغیره و چند متغیره در دوره زمانی ۸۵-۱۳۳۸ پرداخته‌اند. روش‌های مورد استفاده در این مقاله به دو دسته روش‌های تک متغیره شامل الگوریتم باکس جنکینز و مدل فضا-حالت و روش‌های چند متغیره شامل مدل اتورگرسیو برداری و مدل تصحیح خطای برداری برای افق‌های زمانی یک ساله، سه ساله و پنج ساله می‌باشد. نتایج مطالعه آنها، نشان داد که روش‌های تک متغیره به‌طور کلی در پیش‌بینی رشد اقتصادی ایران، بهتر عمل می‌کنند و روش‌های چند متغیره، توانایی پیش‌بینی دقیق‌تر از روش‌های تک متغیره را تنها در کوتاه‌مدت دارند.

نوفرستی و بیات (۱۳۹۲) در مقاله‌ای، به پیش‌بینی رشد اقتصادی ایران به کمک الگوی داده‌های ترکیبی با تواتر متفاوت پرداخته‌اند. آنها از داده‌های تولید ناخالص داخلی و نرخ رشد تعداد پروانه‌های ساختمانی صادره در تواتر فصلی و نرخ رشد قیمت نفت، نرخ رشد سرانه چک‌های برگشتی و نرخ رشد ارز مبادله ای بازار آزاد در تواتر ماهانه استفاده شده است.

متوسلی و مزرعتی (۱۳۹۰) در مطالعه‌ای، به پیش‌بینی و تحلیل سیاستی از تقاضای حامل‌های انرژی ایران شامل فرآورده‌های نفتی، گاز طبیعی و برق با استفاده از مدل‌های VAR، BVAR و SBVAR پرداخته‌اند. تخمین مدل BVAR را با استفاده از اطلاعات پیشین قرینه و عمومی مینسوتا و با روش تایل-گلدبرگر انجام داده‌اند. به منظور بررسی عملکرد پیش‌بینی، از معیارهای U-Theil و RMAPE استفاده نموده که نتایج، حکایت از آن دارد که مدل SBVAR دارای خطای کمتر و عملکرد بهتری در پیش‌بینی بوده است.

در مطالعات تجربی، روش‌های مختلفی برای پیش‌بینی متغیرهای اقتصاد کلان ارائه شده است. همچنین مدل‌های مورد استفاده در این مطالعه، به سه طیف، بزرگ مقیاس (شامل ۱۱۲ متغیر در نه بلوک عاملی)، متوسط مقیاس (شامل ۱۰ متغیر) و مدل‌های تک متغیره دسته‌بندی شده‌اند که این موضوع، از نوآوری‌های دیگر این مطالعه است. لذا نوآوری اصلی این پژوهش، ارائه دیدگاه تحلیلی

وسیع‌تری نسبت مطالعات داخلی و خارجی در خصوص انتخاب مدل‌های مناسب، برای پیش‌بینی رشد اقتصادی است.

#### ۴. تجزیه و تحلیل مدل‌ها و تفسیر نتایج

در این قسمت، به بررسی ویژگی‌های آماری متغیرهای مورد مطالعه پرداخته می‌شود. در این مقاله، از ۱۱۲ متغیر فصلی قابل دسترس از Q1: ۱۳۶۹ تا Q4: ۱۳۹۶ استفاده شده است. به منظور جمع‌آوری داده‌ها، از بانک داده‌های بانک مرکزی جمهوری اسلامی ایران، صندوق بین‌المللی پول، وزارت صنعت، معدن و تجارت، سازمان بورس و اوراق بهادار، مرکز آمار ایران، بانک جهانی و سازمان بین‌المللی کار استفاده شده است. متغیرهای مورد استفاده شامل تولید ناخالص داخلی به عنوان متغیر وابسته و ۱۱۱ متغیر مستقل (پیش‌بینی‌کننده) در ۹ بلوک به منظور استخراج عوامل گنجانده شده‌اند. به طوری که، ۱- بلوک قیمتی شامل مقادیر مختلفی از تورم و شاخص‌های ضمنی و دستمزد می‌باشد (شامل ۲۵ متغیر)؛ ۲- بلوک تقاضا شامل اجزای تولید ناخالص داخلی از سمت تقاضا و برخی دیگر از شاخص‌های مربوط به موجودی سرمایه می‌باشد (شامل ۷ متغیر)؛ ۳- بلوک دولت شامل انواع درآمدها و هزینه‌های دولتی می‌باشد (شامل ۱۳ متغیر)؛ ۴- بلوک خارجی شامل صادرات، واردات، انواع نرخ ارز و همین‌طور نرخ تورم و نرخ ارز کشورهای چین و آلمان (به عنوان بزرگ‌ترین شرکای تجاری ایران) می‌باشد (شامل ۱۷ متغیر)؛ ۵- در بلوک ستاده، از انواع مختلفی از متغیرهای تولیدی استفاده شده است (شامل ۶ متغیر)؛ ۶- بلوک پولی شامل اجزای نقدینگی و پایه پولی می‌باشد (شامل ۲۱ متغیر)؛ ۷- در بلوک مالی، از متغیرهای بازار سرمایه شامل بورس و بیمه استفاده شده است (شامل ۶ متغیر)؛ ۸- بلوک انرژی که شامل متغیرهای مختلف مرتبط با نفت خام و برق و انرژی می‌باشد (شامل ۷ متغیر)؛ ۹- بلوک نیروی کار که شامل متغیرهای مختلف بیکاری و اشتغال و بهره‌وری می‌باشد (شامل ۹ متغیر).

تمام متغیرهای این مقاله، ابتدا با استفاده از X-13 یا TRAMO و یا STL فصلی‌زدایی شده‌اند. با توجه به اینکه متغیرهای پیش‌بینی‌کننده در رویکرد DMA/DMS باید مانا باشند، به بررسی ایستایی متغیرها با استفاده از آزمون‌های ریشه واحد بدون تناوب فصلی (آزمون‌های دیکی فولر  $(ADF)$  و کی. پی. اس. اس.  $(KPSS)$ ) و آزمون ریشه واحد با تناوب فصلی و نیم‌سالانه (آزمون HEGY) پرداخته شد.

نتایج آزمون‌های مذکور در پیوست مقاله، بیانگر آن است که تمامی متغیرهای فاقد هرگونه ریشه واحد با تناوب فصلی و نیم‌سالانه بوده ولیکن دارای ریشه واحد غیرفصلی می‌باشند؛ به‌گونه‌ای که، اگر

$z_{i,t}$  سری‌های غیرتبدیلی اصلی<sup>۱</sup> باشند: ۱- بدون تبدیل (سطح)،  $x_{i,t} = z_{i,t}$ ؛ ۲- با یک مرتبه تفاضل‌گیری  $x_{i,t} = z_{i,t} - z_{i,t-1}$ ؛ ۳- با دو مرتبه تفاضل‌گیری  $x_{i,t} = z_{i,t} - z_{i,t-2}$ ؛ ۴- لگاریتم  $x_{i,t} = \log z_{i,t}$ ؛ ۵- لگاریتم با یک مرتبه تفاضل‌گیری  $x_{i,t} = \log z_{i,t} - \log z_{i,t-1}$ ؛ ۶- لگاریتم با دو مرتبه تفاضل‌گیری  $x_{i,t} = \log z_{i,t} - \log z_{i,t-2}$ . در نهایت، تمام متغیرها با تفاضل از میانگین و تقسیم بر انحراف معیار، استانداردسازی شده‌اند.

به منظور برآورد مدل‌های DMA/DMS، ابتدا یک مدل بلوکی عاملی پویا به صورت معادله (۷) در نظر گرفته می‌شود:

$$y_t = \rho(L)y_t + \sum_{b=1}^B \beta^{(b)}(L)f_t^{(b)} + \varepsilon_t, \quad (7)$$

معادله بالا، با اضافه نمودن تغییر زمانی در ضرایب به صورت زیر فرض می‌شود:

$$y_t = \rho_t(L)y_t + \sum_{b=1}^B \beta_t^{(b)}(L)f_t^{(b)} + \varepsilon_t, \quad (8)$$

$$\theta_{t+1} = \theta_t + \eta_t \quad (9)$$

به طوری که  $f_t^{(b)}$  نشان دهنده عامل استخراج شده از  $b$  امین بلوک متغیرهای پیش‌بینی‌کننده و  $\theta_t$  برداری شامل تمام ضرایب در  $\rho_t(L)$  و  $\beta_t^{(b)}$  است. بنابراین، تمام مدل‌ها بر طبق معادله شامل وقفه‌های متغیر وابسته، عوامل هر بلوک، همچنین وقفه‌های این عوامل هستند. عامل‌ها از طریق روش مؤلفه‌های اساسی<sup>۲</sup> استخراج می‌شوند. اولین عامل برای هر بلوک، استخراج و این عامل و وقفه اول آن ( $p_f = 1$ ) به عنوان متغیرهای پیش‌بینی‌کننده بالقوه در نظر گرفته می‌شود؛ همچنین یک وقفه ( $p_y = 1$ ) از متغیر وابسته و عرض از مبدأ لحاظ می‌شود. این استراتژی، به  $m$  پیش‌بینی‌کننده بالقوه و  $k = 2^m$  مدل منجر می‌شود. با در نظر گرفتن این فروض، تعداد مدل‌ها کاهش می‌یابند: الف) تمام مدل‌ها، حاوی عرض از مبدأ و وقفه‌های متغیر وابسته هستند و ب) در مدل‌های مورد نظر، می‌یابید، هم عامل و هم، وقفه آن، حضور داشته باشند، در غیر این صورت، مدل مورد نظر حذف می‌گردد. زمانی که متغیری پیش‌بینی می‌شود، باید تمام متغیرهای مربوط به آن عامل از بلوک مورد نظر حذف گردد. برای مثال، مدل‌هایی وجود دارد که در آنها، عامل قیمتی و وقفه

1. Original Untransformed Series
2. Principal Components

آن قرار دارد و مدل‌هایی که در آنها، عامل قیمتی و وقفه آن وجود ندارد. با این فرضیات  $h=3$  مدل (۵۱۲) مدل ممکن) در هر لحظه از زمان وجود دارد.

از تحلیل مؤلفه‌های اساسی برای استخراج عوامل با استفاده از تمامی متغیرها در هر بلوک بهره‌گیری به عمل آمده، همانند مطالعه کوپ و کوروبیلیس (Koop & Korobilis, 2012) پیش‌بینی با سه افق کوتاه‌مدت یعنی یک فصل ( $h=1$ )، افق میان مدت یعنی ۴ فصل ( $h=4$ ) و افق بلندمدت یعنی ۸ فصل ( $h=8$ )، در نظر گرفته شده است:

#### ۴-۱. عملکرد پیش‌بینی

دوره زمانی آموزشی پیش‌بینی از Q1:۱۳۶۹ تا Q4:۱۳۷۴ و دوره زمانی بررسی عملکرد پیش‌بینی از Q1:۱۳۷۵ تا Q4:۱۳۹۶ می‌باشد. پیش‌بینی‌ها با استفاده از TVP-AR(1)-X DMA و TVP-AR(1)-X DMS به طوری که "X" بیانگر متغیرهای پیش‌بینی‌کننده برونزای حاضر (نه بلوک عاملی)، علاوه بر آن، پویایی‌های AR(1) هستند.

مقادیر عوامل فراموش شده برای مدل‌های DMA و DMS به صورت  $\alpha = \lambda = 0.99$  مشابه مطالعات مختلف تجربی از جمله رافتری و همکاران (Raftery et al., 2007)؛ کوپ و کوروبیلیس (Koop & Korobilis, 2012)؛ بلمونته و کوپ (Belmonte & Koop, 2013)؛ سالیله (Saleille, 2015)؛ فریرا و پالما (Ferreira & Palma, 2015)؛ فیلیپو (Filippo, 2015)؛ آی و همکاران (Aye et al., 2015)؛ رایس و کرن (Rissea & Kern, 2016)؛ ناصر (Naser, 2016)؛ دراچل (Drachal, 2016) و ناصر و علائی (Naser & Alaali, 2018) در نظر گرفته شده است.

همچنین مقادیر  $\alpha = \lambda = 0.95$  برای عوامل فراموش شده در مدل‌های DMA و DMS مشابه مطالعات مختلف تجربی از جمله: نیکولتی و پاسارو (Nicoletti & Passaro, 2012)؛ کوپ و کوروبیلیس (Koop & Korobilis, 2012)؛ بلمونته و کوپ (Belmonte & Koop, 2013)؛ سالیله (Saleille, 2015)؛ فریرا و پالما (Ferreira & Palma, 2015)؛ فیلیپو (Filippo, 2015)؛ ناصر (Naser, 2016)؛ باور و همکاران (Baur et al., 2016) و دراچل (Drachal, 2016) در نظر گرفته شده است.

از مقادیر  $\alpha = \lambda = 0.9$  برای عوامل فراموش شده در مدل‌های DMA و DMS همانند مطالعات دراچل (Drachal, 2016)؛ باور و همکاران (Baur et al., 2016) و نیکولتی و پاسارو (Nicoletti & Passaro, 2012) در نظر گرفته شده است. مقادیر  $\alpha = 0.99, \lambda = 1$  نیز برای عوامل فراموش شده در مدل DMA همانند مطالعه فریرا و پالما (Ferreira & Palma, 2015)؛ فیلیپو (Filippo, 2015) و آی و همکاران (Aye et al., 2015) در نظر گرفته شده است.

در نهایت، مقادیر  $\alpha = 0.95$ ,  $\lambda = 1$  نیز برای عوامل فراموش شده در مدل DMA همانند مطالعه فیلیپو (Filippo, 2015) در نظر گرفته شده است. مقادیر  $\lambda = 1$  نشان می‌دهد که هیچ وزن فراموش شده‌ای بر ضرایب زمان متغیر وجود ندارد. به عبارت دیگر، تمام خطاهای گذشته در ضرایب تخمینی، به‌روز شده و همچنین در احتمالات پیشین، به‌اندازه مساوی وزن داده شده‌اند.

به منظور مقایسه مدل‌های DMA و DMS از مدل‌های پیش‌بینی زیر استفاده شده است:  
 BMA-1 حالت خاصی از DMA به‌صورت مقادیر فراموش شده  $\alpha = \lambda = 1$  است، که مدلی است که در آن ضرایب، بسیار آرام تکامل می‌یابند (همان‌طور که در تخمین OLS بازگشتی است) و ترکیب مدل‌ها (به‌طور میانگین) در طول نمونه، ثابت است (همان‌طور که در مدل میانگین‌گیری بی‌زین است). به همین دلیل، این مدل همانند مطالعه کوپ و کوروبیلیس (Koop & Korobilis, 2011) به صورت TVP-AR(1)-X BMA در نظر گرفته شده است. در این مدل، هیچ وزن فراموش شده‌ای بر ضرایب زمان متغیر وجود ندارد ( $\lambda = 1$ ) و علاوه بر این، هیچ وزن فراموش شده‌ای بر احتمالات وجود ندارد ( $\alpha = 1$ ). به عبارت دیگر، تمام خطای گذشته در ضرایب تخمینی به‌روز رسانی شده و همچنین احتمالات پسین به میزان مساوی، وزن داده شده‌اند.

۲- با استفاده از ده متغیر مدل خودرگرسیون برداری بیزی (BVAR) براساس منشأ بلافضل و بنیادی برآورد شد؛ به طوری که موجودی سرمایه (۱۰۰=۱۳۸۳) و نرخ مشارکت به عنوان متغیرهای دارای منشأ بلافضل و شاخص قیمت مصرف‌کننده (۱۰۰=۱۳۸۳)، اندازه دولت (کل پرداخت‌های دولت به تولید ناخالص داخلی)، باز بودن تجاری، قیمت نفت سنگین ایران (دلار)، نقدینگی (میلیارد ریال)، نرخ ارز و هزینه‌های مصرف‌نهایی بخش خصوصی (۱۰۰=۱۳۸۳) به عنوان متغیرهای دارای منشأ بنیادی انتخاب شدند. به همین منظور از مدل BVAR با تابع پیشین (Minnesota) استفاده شده است. انتخاب توابع پیشین همانند مطالعه کوپ و کوروبیلیس (Koop & Korobilis, 2010) و بالیسار و همکاران (Balcilar et al, 2018) بوده است.

۳- سپس از مدل‌های پارامتر متغیر در طول زمان با عامل فراموش شده استفاده شده است. در ابتدا، پیش‌بینی‌ها را از یک مدل TVP-AR(1) منفرد (متغیر تولید ناخالص داخلی) تخمینی با عامل فراموش شده ارزیابی می‌شود، برای  $\lambda = 0.99$  که در آن، ضرایب، حرکت نسبتاً آرامی مانند مطالعه کوپ و کوروبیلیس (Koop & Korobilis, 2011, 2012)؛ فریرا و پالما (Ferreira & Palma, 2015)؛ باونسیکا و مورتوب (Buncica & Morettob, 2015) و ناصر و علائی (Naser & Alaali, 2018) دارند و  $\lambda = 0.95$  که در آن، ضرایب، حرکت سریعی همانند مطالعه کوپ و کوروبیلیس (Koop & Korobilis, 2011 & 2012) دارند.



۴- در نهایت، از دو مدل  $AR(1)$  به روش OLS بهره‌گیری به عمل آمده؛ به طوری که در مدل  $AR(1)-X$  از تمام ۹ بلوک عاملی و در مدل  $AR(1)$  تنها از متغیر تولید ناخالص داخلی همانند مطالعه کوپ و کوروبیلیس (Koop & Korobilis, 2011, 2012) استفاده شده است.

به منظور ارزیابی عملکرد پیش‌بینی، از مربع میانگین خطای پیش‌بینی (MSFE)، قدرمطلق میانگین خطای پیش‌بینی (MAFE)، میانگین درصد قدرمطلق خطای پیش‌بینی (MAPE)، تورش خطای پیش‌بینی (Bias) و واریانس خطای پیش‌بینی (FEV) و مجموع لگاریتم احتمالات پیش‌بینی  $Log(PL)$  استفاده شده است. جدول زیر، بیانگر عملکرد پیش‌بینی تولید ناخالص داخلی در مدل‌های مختلف در سه افق پیش‌بینی ( $h=1,4,8$ ) می‌باشد. در افق پیش‌بینی ( $h=1$ ) با بررسی معیارهای (MSFE)، (MAFE)، (MAPE) و (FEV) مدل  $TVP-AR-DMS(\alpha=\lambda=0.9)$  و با معیار (BIAS) مدل  $TVP-AR-DMS(\alpha=\lambda=0.95)$  بهینه بودند. در افق‌های پیش‌بینی ( $h=4,8$ ) با بررسی معیارهای (MSFE)، (MAFE)، (MAPE) و (FEV) مدل  $TVP-AR-DMA(\alpha=\lambda=0.9)$  و با معیار (BIAS) مدل  $TVP-AR-DMS(\alpha=\lambda=0.9)$  بهینه بودند.

همان‌طور که مشاهده می‌شود، DMA و DMS در تمامی افق‌های پیش‌بینی، دارای بهترین عملکرد پیش‌بینی نسبت به سایر مدل‌ها هستند. بنابراین، به نظر می‌رسد، متوسط‌گیری یا گزینشی نمودن الگوی پویا با استفاده از برآورد دقیق مبتنی بر احتمال<sup>۱</sup> مدل‌های TVP با عوامل بلوکی، استراتژی بهینه‌ای است. از سوی دیگر، نتایج حاصل از MSFE، MAFE، MAPE و FEV و BIAS نسبت به احتمال‌های پیش‌بینی، قوی نیستند و تفاوت‌هایی دارند. دلیل این موضوع، آن است که این معیارها، تنها از پیش‌بینی‌های نقطه‌ای<sup>۲</sup> بهره می‌برند، در حالی که احتمال‌های پیش‌بینی از کل توزیع پیش‌بینی کننده استفاده می‌کنند. بنابراین، با بررسی مدل‌های مبتنی بر DMA و DMS با استفاده از معیار LOG(PL)، این نتیجه حاصل شد که در تمامی افق‌های پیش‌بینی مدل  $TVP-AR-DMS(\alpha=\lambda=0.9)$  بهینه‌ای است.

در خصوص مقایسه مدل‌های  $TVP-AR$  همان‌طور که مشاهده می‌شود، در افق پیش‌بینی ( $h=1$ )، بنابر معیارهای (MSFE) و (MAFE)، مدل  $TVP-AR(\lambda=0.99)$  دارای عملکرد بهتری است و بنا بر سایر معیارها و افق‌های پیش‌بینی، مدل  $TVP-AR(\lambda=0.95)$  دارای عملکرد بهتری است. بنابراین، زمانی که تغییرات زمانی بیشتری در پارامترها وجود دارد ( $\lambda=0.95$ )، عملکرد پیش‌بینی بهتر از حالت ( $\lambda=0.99$ ) می‌باشد. علاوه بر این، DMA و DMS همیشه دارای عملکرد

1. Likelihood-Based Estimation
2. Point Forecasts

بهتری نسبت به مدل BMA با پارامترهای با تغییرات آرام، بسیار آرام می‌باشد؛ که این موضوع، نشان می‌دهد که هر دو گونه تغییرات در پارامترها و مدل‌ها، دارای عملکرد بهتری در پیش‌بینی هستند. مدل BVAR تقریباً در تمامی افق‌های پیش‌بینی، ضعیف‌ترین عملکرد را نسبت به سایر مدل‌های مورد استفاده داشته است. نتیجه مقایسه مدل‌های AR(1)-X OLS و AR(1) OLS، بیانگر آن است که در تمامی افق‌های پیش‌بینی، مدل AR(1)-X OLS، دارای عملکرد بهتری نسبت به AR(1) OLS بوده است.


جدول ۱. معیارهای عملکرد پیش‌بینی در افق‌های پیش‌بینی مختلف

	h=1					
	Log(PL)	MAFE	MSFE	MAPE	FEV	Bias
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.99$ )	۷۳,۳۶	۰,۰۷۵۲	۰,۰۱۰۱	۰,۱۹۸۷	۰,۰۰۹۸	۰,۰۱۷۸
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.95$ )	۸۱,۱۸	۰,۰۶۵۸	۰,۰۰۷۷	۰,۱۹۴۷	۰,۰۰۷۴	۰,۰۱۵۴
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.9$ )	۸۲,۹۸	۰,۰۶۰۲	۰,۰۰۶۷	۰,۱۷۸۹	۰,۰۰۶۵	۰,۰۱۴۲
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.99$ )	۷۴,۱۹	۰,۰۸۱۰	۰,۰۱۱۳	۰,۲۰۳۰	۰,۰۱۱۰	۰,۰۱۹۲
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.95$ )	۸۵,۶۲	۰,۰۷۰۸	۰,۰۰۸۷	۰,۱۸۰۰	۰,۰۰۸۵	۰,۰۱۱۸
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.9$ )	۱۰۶,۷۰	۰,۰۵۶۰	۰,۰۰۶۱	۰,۱۶۱۳	۰,۰۰۵۹	۰,۰۱۵۷
<i>TVP-AR(1)-X DMA</i> ( $\alpha = 0.99, \lambda = 1$ )	۷۰,۸۵	۰,۰۷۷۳	۰,۰۱۰۲	۰,۲۰۶۷	۰,۰۰۹۹	۰,۰۱۷۲
<i>TVP-AR(1)-X DMA</i> ( $\alpha = 0.95, \lambda = 1$ )	۷۵,۵۸	۰,۰۷۱۱	۰,۰۰۸۱	۰,۲۳۵۱	۰,۰۰۷۵	۰,۰۲۴۳
<i>TVP-AR(1)-X BMA</i> ( $\alpha = \lambda = 1$ )	۶۶,۷۵	۰,۰۸۴۷	۰,۰۱۲۳	۰,۲۱۲۳	۰,۰۱۲۱	۰,۰۱۴۸
<i>BVAR-Minnesota</i>	-	۰,۰۵۰۰	۰,۰۳۴۱	۰,۷۶۱	۰,۱۱۷	۰,۴۷۳
<i>TVP-AR(1)</i> ( $\lambda = 0.99$ )	-	۰,۰۸۳۱	۰,۰۱۱۹	۰,۲۴۳۰	۰,۰۱۰۹	۰,۰۳۱۷
<i>TVP-AR(1)</i> ( $\lambda = 0.95$ )	-	۰,۰۸۷۸	۰,۰۱۳۰	۰,۲۲۴۰	۰,۰۱۲۲	۰,۰۲۸۷
<i>AR(1)-X(OLS)</i>	-	۰,۱۰۶۱	۰,۰۱۸۶	۰,۲۳۳۵	۰,۰۱۶۱	۰,۰۴۹۲
<i>AR(1)(OLS)</i>	-	۰,۱۴۱۶	۰,۰۳۰۴	۰,۴۶۳۸	۰,۰۱۸۲	۰,۱۱۰۶
	h=۴					
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.99$ )	۶۹,۴۹	۰,۰۷۹۱	۰,۰۱۰۹	۰,۱۹۴۳	۰,۰۱۰۵	۰,۰۲۰۸
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.95$ )	۷۶,۷۶	۰,۰۶۶۲	۰,۰۰۷۸	۰,۱۸۲۳	۰,۰۰۷۶	۰,۰۱۶۲
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.9$ )	۷۸,۰۵	۰,۰۶۰۶	۰,۰۰۶۸	۰,۱۶۹۹	۰,۰۰۶۶	۰,۰۱۴۹
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.99$ )	۶۹,۵۹	۰,۰۸۴۱	۰,۰۱۲۱	۰,۱۹۹۰	۰,۰۱۱۶	۰,۰۲۱۶
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.95$ )	۷۹,۸۷	۰,۰۷۲۳	۰,۰۰۹	۰,۱۷۷۵	۰,۰۰۸۹	۰,۰۱۰۰
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.9$ )	۹۷,۹۲	۰,۰۶۰۹	۰,۰۰۷۱	۰,۱۷۰۹	۰,۰۰۷	۰,۰۱۰۰
<i>TVP-AR(1)-X DMA</i> ( $\alpha = 0.99, \lambda = 1$ )	۶۷,۰۶	۰,۰۷۸۹	۰,۰۱۰۶	۰,۱۹۷۴	۰,۰۱۰۳	۰,۰۱۶۶
<i>TVP-AR(1)-X DMA</i> ( $\alpha = 0.95, \lambda = 1$ )	۷۳,۱۰	۰,۰۷۰۸	۰,۰۰۷۹	۰,۲۰۷۶	۰,۰۰۷۴	۰,۰۲۲۱


<i>TVP-AR(1)-X BMA</i> ( $\alpha = \lambda = 1$ )	۶۳,۲۵	۰,۰۸۷۴	۰,۰۱۲۹	۰,۲۰۵۴	۰,۰۱۲۶	۰,۰۱۵۱
<i>BVAR-Minnesota</i>	-	۰,۵۱۴	۰,۳۸۹	۱,۰۹۶	۰,۱۵۳	۰,۴۸۶۴
<i>TVP-AR(1)</i> ( $\lambda = 0.99$ )	-	۰,۱۴۶۷	۰,۰۳۶۲	۰,۴۲۶۲	۰,۰۳۴۹	۰,۰۳۶۰
<i>TVP-AR(1)</i> ( $\lambda = 0.95$ )	-	۰,۱۳۳۷	۰,۰۳۱۱	۰,۳۷۵۳	۰,۰۳۰۱	۰,۰۳۲۱
<i>AR(1)-X(OLS)</i>	-	۰,۱۰۹۲	۰,۰۱۹۶	۰,۳۱۵۸	۰,۰۱۷۲	۰,۰۴۸۵
<i>AR(1)(OLS)</i>	-	۰,۱۴۷۱	۰,۰۳۲۵	۰,۴۳۵۶	۰,۰۱۹۲	۰,۱۱۵۲
	<b>h=۸</b>					
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.99$ )	۶۵,۴۴	۰,۰۸۱۹	۰,۰۱۱۸	۰,۵۴۹۵	۰,۰۱۱۷	۰,۰۱۱۹
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.95$ )	۷۲,۴۹	۰,۰۶۶۱	۰,۰۰۷۸	۰,۴۰۲۴	۰,۰۰۷۷	۰,۰۱۳۳
<i>TVP-AR(1)-X DMA</i> ( $\alpha = \lambda = 0.9$ )	۷۳,۵۵	۰,۰۶۰۱	۰,۰۰۰۶	۰,۳۱۳۷	۰,۰۰۶۴	۰,۰۱۴۰
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.99$ )	۶۳,۳	۰,۰۸۵۴	۰,۰۱۲۹	۰,۵۵۲۹	۰,۰۱۲۸	۰,۰۱۰۱
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.95$ )	۷۶,۲۷	۰,۰۷۶۳	۰,۰۱۰۱	۰,۴۶۰۴	۰,۰۱۰۰	۰,۰۰۹۹
<i>TVP-AR(1)-X DMS</i> ( $\alpha = \lambda = 0.9$ )	۹۰,۷۱	۰,۰۶۵۵	۰,۰۰۸۴	۰,۴۲۸۰	۰,۰۰۸۳	۰,۰۱۲۳
<i>TVP-AR(1)-X DMA</i> ( $\alpha = 0.99, \lambda = 1$ )	۶۷,۲۱	۰,۰۷۸۲	۰,۰۱۰۲	۰,۵۶۸۶	۰,۰۱۰۱	۰,۰۱۱۳
<i>TVP-AR(1)-X DMA</i> ( $\alpha = 0.95, \lambda = 1$ )	۷۲,۵۵	۰,۰۶۶۵	۰,۰۰۷۱	۰,۴۷۳۱	۰,۰۰۶۹	۰,۰۱۳۶
<i>TVP-AR(1)-X BMA</i> ( $\alpha = \lambda = 1$ )	۶۳,۲۵	۰,۰۸۷۰	۰,۰۱۲۷	۰,۵۷۹۲	۰,۰۱۲۵	۰,۰۱۲۵
<i>BVAR-Minnesota</i>	-	۰,۳۳۶	۰,۱۹۷	۰,۹۱۱	۰,۱۸۷۹	۰,۰۹۶
<i>TVP-AR(1)</i> ( $\lambda = 0.99$ )	-	۰,۲۹۹۳	۰,۱۴۱۹	۳,۶۴	۰,۱۰۲۱	۰,۱۹۹۵
<i>TVP-AR(1)</i> ( $\lambda = 0.95$ )	-	۰,۲۳۳۳	۰,۰۸۹۳	۲,۵۵	۰,۰۸۱۳	۰,۰۸۹۳
<i>AR(1)-X(OLS)</i>	-	۰,۱۰۳۸	۰,۰۱۷۵	۰,۸۹۵۱	۰,۰۱۶۱	۰,۰۳۷۲
<i>AR(1)(OLS)</i>	-	۰,۱۴۶۰	۰,۰۳۲۴	۱,۰۲۵۵	۰,۰۱۹۹	۰,۱۱۱۷

مأخذ: یافته‌های پژوهش


همان‌طور که مشاهده می‌شود، نمودارهای زیر، ارائه‌دهنده پیش‌بینی برون نمونه‌ای به روش‌های *DMA*، *DMS* و *AR(1)-OLS* در افق‌های  $h=1,4,8$  می‌باشد. بر اساس پیش‌بینی‌های صورت‌گرفته با روش‌های *DMA* و *DMS*، نرخ رشد اقتصادی به‌طور متوسط در طول سال ۱۳۹۷ منفی و با روش *AR(1)* مثبت خواهد شد. در سال ۱۳۹۸ نیز نرخ رشد اقتصادی به‌وسیله روش‌های *DMA* و *DMS* نسبت به سال ۱۳۹۷ با بهبود ولیکن به‌وسیله روش *AR(1)* با کاهش نسبت به سال ۱۳۹۷ روبرو خواهد شد. البته لازم به ذکر می‌باشد، نتایج حاصل با توجه به ثبات شرایط کشور و مطابق با داده‌های تاریخی صورت گرفته است.



نمودار ۲. مقایسه پیش‌بینی برون نمونه‌ای در یک گام جلوتر ( $h=1$ )



نمودار ۳. مقایسه پیش‌بینی برون نمونه‌ای در چهار گام جلوتر ( $h=4$ )




نمودار ۴. مقایسه پیش‌بینی برون نمونه‌ای در هشت گام جلوتر (H=8)

مأخذ: یافته‌های پژوهش

همان‌طور که مطرح شد، از میان مدل‌های پیش‌بینی، تنها DMA و DMS، اجازه تغییر مدل‌های پیش‌بینی را در طول زمان می‌دهد. با توجه به تعداد بسیار زیاد مدل‌ها (۵۱۲ مدل)، نمی‌توان نتایج را برای هر مدل ارائه نمود. اگر چه می‌توان ۹ بلوک عاملی را به طور بالقوه انتخاب نمود، ولیکن به علت اصل صرفه‌جویی، در اکثر مواقع، تعداد کمتری بلوک به عنوان وزن در مدل DMA/DMS استفاده می‌شوند. اگر  $Size_k$  به عنوان تعداد بلوک‌های عاملی در مدل K در نظر گرفته شود، می‌توان تعداد بلوک‌های عاملی متوسط یا مورد انتظار استفاده شده در DMA/DMS در زمان t را به صورت

$$E(Size_t) = \sum_{k=1}^K \pi_{t|t-1,k} Size_k$$

در هر پیش‌بینی در هر لحظه از زمان می‌باشد. همان‌طور که در نمودار مشاهده می‌شود، مدل پیش‌بینی در طول زمان تغییر می‌کند و علاوه بر این، اصل صرفه‌جویی نیز در این مدل‌ها رعایت شده است.



نمودار ۵. متوسط تعداد بلوک‌های عاملی پیش‌بینی کننده در هر تمرین پیش‌بینی

مأخذ: یافته‌های پژوهش

جدول زیر، نشان‌دهنده تعداد استفاده از بلوک‌ها در پیش‌بینی مدل بهینه در افق‌های پیش‌بینی مدنظر است. یافته‌ها حاکی از آن است که در تمامی افق‌های پیش‌بینی، بلوک تقاضا و انرژی دارای بیشترین تعداد در استفاده از مدل بهینه در طول زمان بوده و کمترین تعداد نیز به بلوک قیمتی اختصاص داشته است.


جدول ۲. اولویت‌بندی تعداد بلوک‌های مورد استفاده در پیش‌بینی مدل بهینه در افق‌های پیش‌بینی مختلف

h=۱								
بلوک تقاضا	بلوک انرژی	بلوک ستاده	بلوک خارجی	بلوک پولی	بلوک مالی	بلوک نیروی کار	بلوک دولت	بلوک قیمتی
۵۲	۴۲	۳۳	۲۵	۲۳	۲۳	۲۱	۱۸	۱۵
h=۴								
بلوک تقاضا	بلوک انرژی	بلوک خارجی	بلوک ستاده	بلوک پولی	بلوک دولت	بلوک نیروی کار	بلوک مالی	بلوک قیمتی
۴۹	۳۹	۳۸	۲۷	۲۶	۱۴	۱۳	۱۳	۸
h=۸								
بلوک تقاضا	بلوک خارجی	بلوک انرژی	بلوک پولی	بلوک ستاده	بلوک نیروی کار	بلوک دولت	بلوک مالی	بلوک قیمتی
۵۷	۴۹	۴۴	۲۴	۱۵	۱۳	۹	۴	۳





مأخذ: یافته‌های پژوهش

همان‌طور که مطرح شد، رافتری و همکاران (Raftery et al, 2007)، الگوریتم DMA با احتمالات زمان متغیر مرتبط با هر مدل را بیان نمودند (به عنوان مثال،  $\pi_{t|t-1,k}$  برای  $t = 1, \dots, T$  و  $k = 1, \dots, K$ ). برای هر بلوک عاملی در هر نقطه از زمان، می‌توان از این مورد برای محاسبه احتمال کل مرتبط با مدل‌های حاوی عامل بلوک خاص (و وقفه آن) استفاده نمود؛ به این معنی که برای  $b = 1, \dots, B$  می‌توان  $\sum_{k \in b} \pi_{t|t-1,k}$  را محاسبه نمود که به معنی مجموع مدل‌هایی است که حاوی b امین بلوک عاملی است.

نمودار زیر، بیانگر این احتمالها برای ۹ بلوک عاملی در افقهای پیش‌بینی مختلف است. اگر خطوط این نمودارها برای هر بلوک عاملی دقیقاً برابر با یک باشد، روش DMA تنها مدلهایی را که حاوی این بلوک عاملی باشد، برای پیش‌بینی استفاده می‌کند و بنابراین، این بلوک عاملی، یک پیش‌بینی کننده با اهمیت محسوب می‌شود. چنانچه خطوط این نمودارها برای هر بلوک عاملی دقیقاً برابر با صفر باشد، روش DMA به‌طور کامل کلیه مدلهای حاوی این بلوک عاملی را در پیش‌بینی حذف می‌کند. خطوطی که بین صفر و یک قرار می‌گیرند، دارای یک تفسیر میانی<sup>۱</sup> می‌باشند. همان‌طور که در نمودار مشاهده می‌شود، به‌ندرت خطوطی نزدیک به یک یا صفر قرار گرفته است؛ که این موضوع نشان می‌دهد، مدل DMA میانگین‌گیری تعداد زیادی مدل است و تنها از یک بلوک عاملی استفاده نمی‌کند - همچنین بلوک عاملی بی‌ربطی نیز وجود ندارد. این موضوع، مهم‌ترین ویژگی استفاده از DMA/DMS است.



## 1. Intermediate Interpretation



نمودار ۶. احتمال کل از مدل‌های حاوی هر بلوک عاملی در افق‌های پیش‌بینی مختلف

مأخذ: یافته‌های پژوهش



## ۵. نتیجه‌گیری

روند تغییرات بسیاری از متغیرهای اقتصادی با توجه به روابطی که این متغیرها با سایر متغیرها و از جمله متغیرهای سیاستگذاری دارند، قابل پیش‌بینی است. روند فزاینده انتشار آمار و اطلاعات اقتصادی، پیشرفت نظریه‌های اقتصادی، به‌کارگیری روش‌های پیشرفته‌تر اقتصادسنجی و نرم‌افزارها، باعث کمک به محققان اقتصادی در پیش‌بینی قابل اعتمادتر از تحولات اقتصادی شده و این موضوع در پیش‌بینی تحولات اقتصادی ایران نیز می‌تواند با شناسایی مدل‌های مناسب پیش‌بینی صادق باشد. مدل‌های DMA و DMS نسبت به سایر مدل‌های پیش‌بینی، دارای مزیت‌هایی است، از جمله اینکه این مدل‌ها اجازه می‌دهند ضرایب در طول زمان تغییر کنند؛ همچنین اجازه می‌دهند که متغیرهای پیش‌بینی کننده مورد استفاده در پیش‌بینی و مدل‌ها در طول زمان تغییر کنند. در حقیقت، مدل‌های پیش‌بینی خوب می‌باید انعطاف‌پذیر بوده و به سرعت با توجه به تغییرات فرایند ایجاد داده (DGP)، سازگار شوند. علاوه بر این، انقباض از طریق مدل‌های متوسط‌گیری و گزینشی نمودن، یکی دیگر از ویژگی‌های مطلوب، به منظور مقابله با موضوع بیش‌برازشی است.

از این رو در این مقاله، به مقایسه روش‌های مختلف پیش‌بینی رشد اقتصادی ایران با تأکید بر رویکرد DMA و DMS با استفاده از رویکرد بلوک عاملی در سه افق پیش‌بینی  $h=1, 4, 8$  فصل، پرداخته شده است. مدل‌های مورد استفاده در این مقاله، به سه طیف، بزرگ مقیاس، متوسط مقیاس و مدل‌های تک متغیره تقسیم شده‌اند؛ به‌گونه‌ای که مدل‌های بزرگ مقیاس شامل ۱۱۲ متغیر در ۹ بلوک عاملی قیمتی، تقاضا، دولت، خارجی، ستاده، پولی، مالی، انرژی و نیروی کار بوده و با استفاده از DMA/DMS با توجه به عوامل فراموش شده مختلف و همین‌طور BMA و AR-X OLS، تخمین زده شده‌اند. مدل متوسط مقیاس که شامل ۱۰ متغیر اقتصاد کلان است و با توجه به مبانی نظری رشد اقتصادی با منشأهای بلافصل و بنیادی انتخاب شده‌اند، با استفاده از BVAR با تابع پیشین Minnesota برآورد شده است. علاوه بر این، از مدل‌های تک متغیره، به‌صورت TVP-AR با  $\lambda$  های مختلف و همین‌طور AR OLS تخمین زده شده‌اند.

نتایج، حاکی از آن است که مدل‌های AR(1) OLS و AR(1)-X OLS بهتر از مدل BVAR بوده و مدل‌های TVP-AR(1) نیز دارای عملکرد بهتری نسبت به مدل‌های AR OLS و همین‌طور مدل BMA. از عملکرد بهتری نسبت به مدل TVP برخوردار بوده‌اند. در نهایت، مدل‌های DMA و DMS، دارای بهترین عملکرد پیش‌بینی و مدل DMS نسبت به مدل DMA از عملکرد بهتری در پیش‌بینی رشد اقتصادی کشور برخوردار بوده است.

## 1. Data-Generation Process (DGP)

علاوه بر این، استفاده از بلوک عاملی، نشان داد که عوامل پیش‌بینی کننده در طول زمان دچار تغییر می‌شوند. یافته‌ها حاکی از آن است که در تمامی افق‌های پیش‌بینی بلوک تقاضا و انرژی، دارای بیشترین تعداد در استفاده از مدل بهینه در طول زمان بوده و کمترین تعداد نیز به بلوک قیمتی اختصاص داشته است. علاوه بر این، احتمال کل از مدل‌های حاوی هر بلوک عاملی در افق‌های پیش‌بینی مختلف، به‌ندرت نزدیک به یک یا صفر قرار گرفت که این موضوع، نشان می‌دهد که مدل DMA، میانگین‌گیری تعداد زیادی مدل است و تنها از یک بلوک عاملی استفاده نمی‌کند - همچنین بلوک عاملی بی‌ربطی نیز وجود ندارد - و این موضوع، مهم‌ترین ویژگی استفاده از DMA/DMS است.

لذا پیشنهاد می‌گردد که سیاستگذاران حوزه اقتصاد کشور، به‌عنوان یک ابزار مناسب برای پیش‌بینی مقادیر آتی رشد اقتصادی، روش‌های DMA/DMS بلوکی در نظر بگیرند. همچنین این مدل‌ها را برای سایر متغیرهای اقتصاد کلان مانند تورم، ارز، قیمت سهام بورس اوراق بهادار تهران و ... که برای سیاستگذاری اهمیت دارند نیز مورد استفاده قرار دهند. همچنین به محققان بعدی، پیشنهاد می‌گردد که پیش‌بینی برون نمونه‌ای با هر یک از این روش‌ها مورد بررسی قرار گیرد.

## منابع

- آرمن، سید عزیز و تبعه ایزدی، امین (۱۳۹۲). پیش بینی رشد اقتصادی ایران: مقایسه مدل‌های سری زمانی تک متغیره و چند متغیره. *فصلنامه اقتصاد مقداری*، دوره ۱۰، شماره ۲، تابستان: ۱-۳۹.
- بیانی، عذرا و محمدی، تیمور (۱۳۹۸). عوامل مؤثر بر بحران‌های مالی در اقتصاد ایران: رویکرد میانگین‌گیری بیزی. *فصلنامه اقتصاد مقداری*، دوره ۱۶، شماره ۲، تابستان: ۱۴۵-۱۸۰.
- حیدری، حسن و جوهری سلماسی، پریسا (۱۳۹۴). عملکرد مدل‌های مختلف خودرگرسیون برداری بیزی جهت پیش‌بینی متغیرهای کلان اقتصادی ایران: کاربرد روش نمونه‌گیری گیبس. *فصلنامه پژوهش‌های اقتصادی ایران*، سال بیستم، شماره ۶۲: ۵۷-۷۶.
- خدایی، مهدی؛ جعفری، محمد و فتاحی، شهرام (۱۳۹۷). بررسی اثرات سیاست‌های مالی بر رشد اقتصادی در اقتصاد ایران: مدل‌های فضا-حالت. *فصلنامه پژوهش‌های رشد و توسعه اقتصادی*، سال هشتم، شماره سی و یکم، تابستان: ۷۹-۹۲.
- متوسلی، محمود و مزرعتی، محمد (۱۳۹۰). پیش‌بینی و تحلیل سیاستی از تقاضای حامل‌های انرژی در ایران با مدل‌های VAR.BVAR و پیشنهاد مدل‌های SBVAR. *مجله برنامه و بودجه*، شماره ۴۳ و ۴۴: ۲۹-۷۶.
- مهرآرا، محسن؛ رضائی برگشادی، صادق و حامدی، سهیلا (۱۳۹۵). تأثیر مصرف انرژی بر رشد اقتصادی ایران؛ رهیافت بیزی. *فصلنامه پژوهش‌های سیاست‌گذاری و برنامه ریزی انرژی*، سال دوم، شماره ۳، تابستان: ۱۰۱-۶۱.
- نوفروستی، محمد و بیات، محبوبه (۱۳۹۲). پیش‌بینی رشد اقتصادی ایران به کمک الگوی داده‌های ترکیبی با تواتر متفاوت. *فصلنامه اقتصاد و الگوسازی دانشگاه شهید بهشتی*، تابستان و پاییز.
- Angelini, E.; Banbura, M., & Runstler, G., (2010). Estimating and forecasting the Euro area monthly national accounts from a dynamic factor model. *OECD Journal: Journal of Business Cycle Measurement and Analysis*, (1): 1-22.
- Artis, M.; Banerjee, A., & Marcellino, M. (2005). Factor forecasts for the UK. *Journal of Forecasting*, 24 (4): 279-298.
- Aye, G.; Gupta, R.; Hammoudeh, Sh., & Kim, W. J. (2014). Forecasting the Price of Gold Using Dynamic Model Averaging. University of Pretoria, Department of Economics Working Paper Series.
- Balcilar, M.; Gupta, R.; Eyden, R.; Thompson, K., & Majumdar, A. (2018). Comparing the forecasting ability of financial conditions indices: The case of South Africa. *The Quarterly Review of Economics and Finance*, 69(C): 245-259.
- Banbura, M.; Giannone, D., & Reichlin, L. (2010). Large bayesian vector auto regressions. *Journal of Applied Econometrics*, 25(1): 71-92.

- Barsoum, F., & Stankiewicz, S. (2013). Forecasting GDP Growth Using Mixed-Frequency Models With Switching Regimes. Working Paper Series, University of Konstanz, Department of Economics.
- Baur, D. G.; Beckmann, J., & Czudaj, R. (2016). A melting pot-gold price forecasts under model and parameter uncertainty. *International Review of Financial Analysis*, 48: 282-291.
- Belmonte, M., & Koop, G. (2014). Model Switching and Model Averaging in Time-Varying Parameter Regression Models. in Ivan Jeliazkov, Dale J. Poirier (ed.) Bayesian Model Comparison (Advances in Econometrics, Volume 34) Emerald Group Publishing Limited: 45-69.
- Bernanke, B. S., & Boivin, J. (2003). Monetary policy in a data-rich environment. *Journal of Monetary Economics*, 50 (3): 525-546.
- Bernanke, Ben S.; Boivin, J., & Elias, P. (2005). Measuring the effects of monetary policy: A Factor-Augmented Vector Autoregressive (FAVAR) Approach. *Quarterly Journal of Economics*, 120: 387-422.
- Boivin, J., & Ng, S. (2006). Are more data always better for factor analysis?. *Journal of Econometrics*, 132 (1): 169-194.
- Bork, L., & Møller, S.V. (2014). Forecasting House Prices in the 50 States Using Dynamic Model Averaging and Dynamic Model Selection. Macroeconomic Methodology, Theory and Economic Policy (MaMTEP), No. 2, Working Paper Series Department of Business & Management.
- Buncic, D., & Moretto, C. (2015). Forecasting copper prices with dynamic averaging and selection models. *North American Journal of Economics and Finance*, 33: 1-38.
- Carnot N., Koen, V., & Tissot B. (2005). Economic forecasting. Palgrave Macmillan.
- Clements, M. P., & Krolzig, H. M. (1998). A comparison of the forecast performance of Markov-switching and Threshold Autoregressive Models of US GNP. *The Econometrics Journal*, 1 (1): 47-75.
- Clements, M. P., & Smith, J. (1997). The performance of alternative forecasting methods for SETAR models. *International Journal of Forecasting*, 13 (4): 463-475.
- Cogley, T., & Sargent, T. (2005). Drifts and volatilities: Monetary policies and outcomes in The post WWII U.S. *Review of Economic Dynamics*, 8: 262-302.
- Cogley, T.; Morozov, S., & Sargent, T. (2005). Bayesian fan charts for U.K. inflation: Forecasting and sources of uncertainty in an evolving monetary system. *Journal of Economic Dynamics and Control*, 29: 1893-1925.
- D'Agostino, A., & Giannone, D. (2012). Comparing alternative predictors based on large-panel factor models. *Oxford bulletin of economics and statistics*, 74 (2): 306-326.

- De Mol, C.; Giannone, D., & Reichlin, L. (2008). Forecasting using a large number of predictors: Is bayesian shrinkage a valid alternative to principal components?. *Journal of Econometrics*, 146(2): 318-328.
- Drachal, K. (2016). Forecasting spot oil price in a dynamic model averaging framework have the determinants changed over time?. *Energy Economics*, 60: 35-46.
- Elliott, G., & Timmermann, A. (2013). Handbook of economic forecasting. North Holland, Handbook of Economic Forecasting, Volume 2.
- Engle, R., & Granger, C. (1987). Co-integration and error correction: Representation, estimation, and testing. *Econometrica: Journal of the Econometric Society*, 55(2): 251-276.
- Engle, R., & Yoo, B. (1987). Forecasting and testing in co-integrated systems. *Journal of econometrics*, 35 (1): 143-159.
- Ferreira, D., & Palma A. (2015). Forecasting inflation with the Phillips curve: A dynamic model averaging approach for Brazil. *Rev. Bras.Econ*, 69(4): 451-465.
- Filippo, D.G. (2015). Dynamic model averaging and CPI inflation forecasts: A comparison between the Euro area and the United States. *Journal of Forecasting*, 34(8): 619-648.
- Forni, M.; Giannone, D.; Lippi, M., & Reichlin, L. (2009). Opening the black box: Structural factor models with large cross-sections. *Econometric Theory*, 25 (5): 1319-47.
- Forni, M.; Hallin, M.; Lippi, M., & Reichlin, L. (2000). The generalized dynamic factor model: Identification and estimation. *Review of Economics and Statistics*, 82 (4): 540-554.
- Forni, M.; Hallin, M.; Lippi, M., & Reichlin, L. (2003). Do financial variables help forecasting inflation and real activity in the Euro area?. *Journal of Monetary Economics*, 50 (6): 1243-55.
- Geweke, J. (1977). The dynamic factor analysis of economic time-series. in latent variables in socio-economic models, edited by D. Aigner and A. Gold Berger.
- Gupta, R. (2006). Forecasting the South African economy with VARs and VECMs. *South African Journal of Economics*, 74 (4): 611-628.
- Gupta, R.; Hammoudeh, Sh.; Kim, W.J., & Simo-Kengne, B.D. (2014). Forecasting China's foreign exchange reserves using dynamic model averaging: The roles of macroeconomic fundamentals, financial stress and economic uncertainty. *North American Journal of Economics and Finance*, 28: 170-189.
- Hamilton, J. (1989). A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, 57 (2): 357-384.
- Holden, K.; Peel, D.A., & Thompson, J.L. (1999). *Economic Forecasting: An Introduction*. Cambridge University Press.

- Khezri, M.; Hosseinidoust, S.E., & Naziri, M.K. (2019). Investigating the temporary and permanent influential variables on Iran inflation using TVP-DMA models. *Iranian Economic Review*, 23(1): 209-234.
- Koop, G. (2012). Using VARs and TVP-VARs with many macroeconomic variables. *Central European Journal of Economic Modelling and Econometrics*, 4: 143-167, working paper version.
- Koop, G., & Korobilis, D. (2010). Bayesian multivariate time series methods for empirical macroeconomics. *Foundations and Trends in Econometrics*, 3(4): 267-358.
- Koop, G., & Korobilis, D. (2011). UK macroeconomic forecasting with many predictors: Which models forecast best and when do they do so?. *Economic Modelling*, 28: 2307-18.
- Koop, G., & Korobilis, D. (2012). Forecasting inflation using dynamic model averaging. *International Economic Review*, 53(3): 867-886.
- Litterman, R. B. (1986). Forecasting with Bayesian vector autoregressions five years of experience. *Journal of Business & Economic Statistics*, 4(1):25-38.
- Marcellino, M.; Stock, J., & Watson M. (2003). Macroeconomic forecasting in the Euro area: Country specific versus area-wide information. *European Economic Review*, 47 (1): 1-18.
- Naser, H. (2014). An Econometric Investigation of Forecasting GDP, Oil Prices, and Relationships among GDP and Energy Sources. PhD thesis. University of Sheffield.
- Naser, H., & Alaali, F. (2018). Can oil prices help predict US stock market returns: An evidence using a DMA approach. *Empirical Economics*, 55(4): 1757-77.
- Ng, S.; Moench, E., & Potter, S., (2008). Dynamic Hierarchical Factor Models. *Manuscript*. available at <http://www.columbia.edu/sn2294/papers/dhfm-short.pdf> 2008.
- Nicoletti, G., & Passaro, R. (2012). Sometimes it helps the evolving predictive power of spreads on GDP dynamics, Working Paper Series, European Central Bank, No. 1447.
- Onorante, L., & Raftery, A.E. (2016). Dynamic model averaging in large model spaces. *European Economic Review*, 81: 2-14.
- Primiceri, G. (2005). Time varying structural autoregressions and monetary policy. *Review of Economic Studies*, 72: 821-852.
- Raftery, A.; Karny, M.; Andrysek, J., & Ettl, P. (2007). Online prediction under model uncertainty via dynamic model averaging: Application to a cold rolling mill. Technical report, 525. Department of Statistics, University of Washington.
- Raftery, A.E.; Karny, M., & Ettl, P. (2010). Online prediction under model uncertainty via dynamic model averaging: *application to a cold rolling mill*. *Technometrics* 52(1): 52–66.

- Risse M., & Kern M. (2016). Forecasting house-price growth in the Euro area with dynamic model averaging. *The North American Journal of Economics and Finance*, 38: 70-85.
- Saille, N. (2015). Forecasting the French GDP: Essay on statistical models to forecast aggregate macroeconomic variables. Master thesis, Paris School of Economics.
- Schumacher, C. (2007). Forecasting German GDP using alternative factor models based on large datasets. *Journal of Forecasting*, 26 (4): 271-302.
- Sims, C. A. (1980). Macroeconomics and reality. *Econometrica: Journal of the Econometric Society*, 48(1): 1-48.
- Sims, C. A., & Zha, T. (2006). Were there regime switches in U.S. monetary policy?. *American Economic Review*, 96(1): 54-81.
- Stock, J., & Watson, M. (1998). Diffusion indexes. NBER Working Paper No.w6702.
- Stock, J., & Watson, M. (2002a). Forecasting using principal components from a large number of predictors. *Journal of the American statistical association*, 97 (460): 1167-79.
- Stock, J., & Watson, M. (2002b). Macroeconomic forecasting using diffusion indexes. *Journal of Business & Economic Statistics*, 20 (2): 147-162.
- Stock, J., & Watson, M. (2005). An Empirical Comparison of Methods for Forecasting using Many Predictors. Manuscript, Princeton University.
- Stock, J., & Watson, M. (2006). Macroeconomic forecasting using many predictors. In: Elliott, G., Granger, C., Timmerman, A. (Eds.), *Handbook of Economic Forecasting*. North Holland, Amsterdam.
- Varian, H. R. (2014). Big data: New tricks for econometrics. *The Journal of Economic Perspectives*, 28(2): 3-28.