



فصلنامه‌ی اقتصاد مقداری

صفحه‌ی اصلی وب سایت مجله:

www.jqe.scu.ac.ir

شاپا الکترونیکی: ۲۷۱۷-۴۲۷۱

شاپا چاپی: ۲۰۰۸-۵۸۵۰



دانشگاه شهیدپرآن ابواز

مقایسه پیش‌بینی نرخ تورم مصرف‌کننده ایران با استفاده از تعداد بسیاری متغیر پیش‌بینی‌کننده

تیمور محمدی^{ID} *، جاوید بهرامی **، فاطمه فهیمی فر ***

* دانشیار اقتصاد، گروه اقتصاد نظری، دانشکده اقتصاد، دانشگاه علامه طباطبائی، تهران، ایران (نویسنده مسئول).

** دانشیار اقتصاد، گروه اقتصاد بازرگانی، دانشکده اقتصاد، دانشگاه علامه طباطبائی، تهران، ایران.

*** دانشجوی دکتری علوم اقتصادی، گروه اقتصاد، دانشکده اقتصاد، دانشگاه علامه طباطبائی، تهران، ایران.

اطلاعات مقاله	طبقه‌بندی JEL: C32, C38, C53, E37, E31
تاریخ دریافت: ۱۷ آذر ۱۳۹۸	واژگان کلیدی:
تاریخ بازنگری: ۱۵ اسفند ۱۳۹۸	پیش‌بینی، نرخ تورم مصرف‌کننده، مدل فضا-حالت، مدل عاملی، متوسط‌گیری الگوی پویا
تاریخ پذیرش: ۲۴ خرداد ۱۳۹۹	آدرس پستی:
ارتباط با نویسنده (گان) مسئول:	تهران، خیابان شهید بهشتی، نبش احمد قیصر، دانشکده اقتصاد
ایمیل: atmahmadi@gmail.com	دانشگاه علامه طباطبائی
0000-0003-4394-774X ^{ID}	

اطلاعات تکمیلی:

این مقاله برگرفته از پایان نامه‌ی دکترای خانم فاطمه فهیمی فر در رشته علوم اقتصادی به راهنمایی آقای دکتر تیمور محمدی در دانشگاه علامه طباطبائی است.

قدردانی: از تمامی افراد و موسساتی که در انجام این تحقیق مولف را مساعدت نمودند، قدردانی می‌شود.
تضاد منافع: نویسندگان مقاله اعلام می‌کنند که در انتشار مقاله ارائه شده تضاد منافی وجود ندارد.
منابع مالی: نویسنده‌ها هیچگونه حمایت مالی برای تحقیق، تألیف و انتشار این مقاله دریافت نکرده‌اند.

چکیده

یکی از مهم‌ترین مشکلات اقتصادی در ایران طی چند دهه اخیر پدیده‌ی تورم بالا و دو رقمی است، به طوری که بهبود شرایط ناشی از وجود تورم بالا همواره یکی از اهداف مهم برنامه‌های توسعه کشور بوده است. دستیابی به این هدف مستلزم ایجاد ساز و کاری دقیق و هدفمند از فرآیند سیاست‌گذاری اقتصادی است که در شکل استاندارد خود، پیش‌بینی، هدف‌گذاری و تحلیل سیاستی را شامل می‌گردد. در این مطالعه از ۱۰۸ متغیر فصلی در دوره زمانی ۹۶-۱۳۷۹ استفاده شده است. متغیرهای مورد استفاده شامل شاخص قیمت مصرف‌کننده به عنوان متغیر وابسته و ۱۰۷ متغیر مستقل (پیش‌بینی‌کننده) بوده که در نه بلوک (بلوک قیمتی، بلوک تقاضا، بلوک دولت، بلوک خارجی، بلوک ستاده، بلوک پولی، بلوک مالی، بلوک انرژی و بلوک نیروی کار) به منظور استخراج عوامل گنجانده شده‌اند. از تحلیل مؤلفه‌های اساسی برای استخراج عوامل با استفاده از تمامی متغیرها در هر بلوک استفاده شده است. علاوه بر این، وقفه‌های هر مدل با استفاده از BIC تعیین شده‌اند. همانند مطالعه کوپ و کورویلیس (۲۰۱۲) پیش‌بینی‌ها با سه افق کوتاه‌مدت ($n=1$)، افق میان‌مدت ($n=4$) و افق بلندمدت ($n=8$) در نظر گرفته شده است. هدف اصلی این مطالعه، مقایسه عملکرد پیش‌بینی مدل‌های DMA و DMS با $BVAR$ ، BMA ، TVP و AR می‌باشد. به منظور ارزیابی عملکرد پیش‌بینی از مربع میانگین خطای پیش‌بینی، قدرمطلق میانگین خطای پیش‌بینی، میانگین درصد قدرمطلق خطای پیش‌بینی، تورش خطای پیش‌بینی و واریانس خطای پیش‌بینی و مجموع لگاریتم احتمالات پیش‌بینی استفاده شده است. علاوه بر این، به منظور مقایسه صحت پیش‌بینی از آزمون دیبولد-مارینو (۱۹۹۵) استفاده شد. نتایج مطالعه نشان می‌دهد که پیش‌بینی مدل‌های گزینشی نمودن (DMS) و متوسط‌گیری الگوی پویا (DMA) نسبت به سایر روش‌های پیش‌بینی سنتی دارای عملکرد کاراتری برای نرخ تورم ایران هستند. یافته‌ها حاکی از آن است که در تمامی افق‌های پیش‌بینی، بلوک‌های پولی و قیمتی دارای بیشترین تعداد در استفاده از مدل بهینه در طول زمان بوده و کمترین تعداد نیز به بلوک دولت اختصاص داشته است.

ارجاع به مقاله:

محمدی، تیمور، بهرامی، جاوید و فهیمی فر، فاطمه. (۱۴۰۰). مقایسه پیش‌بینی نرخ تورم مصرف‌کننده ایران با استفاده از تعداد بسیاری متغیر پیش‌بینی‌کننده. فصلنامه‌ی اقتصاد مقداری (بررسی‌های اقتصادی سابق)، ۱۸(۴)، ۱۵۹-۱۹۰.

 [10.22055/JQE.2020.31882.2190](https://doi.org/10.22055/JQE.2020.31882.2190)



© 2022 Shahid Chamran University of Ahvaz, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0 license) (<http://creativecommons.org/licenses/by-nc/4.0/>)

۱- مقدمه

پیش‌بینی متغیرها به دو دلیل اساسی دارای اهمیت می‌باشد، اول به علت آینده نامعلوم و دوم به دلیل آنکه بسیاری از تصمیماتی که در حال حاضر گرفته می‌شود، تأثیر کامل‌شان در آینده اتفاق می‌افتد. در نتیجه، پیش‌بینی‌های دقیق از آینده، منجر به بهبود کارایی فرآیند تصمیم‌گیری و سیاست‌گذاری می‌شود (Holden, Peel & Thompson, 1999). دولت، صنعت و عوامل مالی نیازمند اطلاع از روند حرکتی آینده متغیرهای کلان اقتصادی و در نتیجه پیش‌بینی آنها می‌باشند. پیش‌بینی‌های اقتصادی می‌توانند به عوامل اقتصادی در بخش خصوصی به عنوان مثال تصمیم یک بنگاه برای سرمایه‌گذاری یا تمایل خانوار برای پیش‌بینی درآمد آینده‌اش کمک نمایند (Carnot, Koen & Tissot, 2005). همچنین دولت‌ها به منظور اطلاع از پیامدهای سیاست‌گذاری‌های کلان خود و ایجاد ثبات اقتصاد کلان، به پیش‌بینی نرخ رشد اقتصادی داخلی و جهانی، نرخ تورم، نیروی کار، سرمایه‌گذاری و نرخ ارز می‌پردازند (Holden, Peel & Thompson, 1999).

پیش‌بینی تورم برای خانوارها، تجار و سیاست‌گذاران بسیار با اهمیت است. تفاوت مهمی بین پیش‌بینی تورم توسط بانک مرکزی و پیش‌بینی تورم توسط عموم افراد جامعه وجود دارد. برخلاف افراد جامعه، بانک مرکزی بر سیاست پولی کنترل دارد که به نوبه خود بر تورم تأثیر می‌گذارد (Elliott & Timmermann, 2013). دولت و بانک مرکزی، سیاست‌های مالی و پولی را بر اساس تغییرات آتی کوتاه‌مدت و بلندمدت تورم بنا می‌کنند. پیش‌بینی تورم با خطای کم، یکی از رمزهای موفقیت این سیاست‌ها به شمار می‌آید. بنابراین، دقت پیش‌بینی در رابطه با این شاخص از حساسیت زیادی برخوردار است. به همین دلیل، یک روش پیش‌بینی قابل اعتماد به شدت مورد نیاز است، اما بسیاری از مدل‌های موجود در این زمینه با کاستی‌هایی همراه هستند (Barsoum & Stankiewicz, 2013). دستیابی به روشی که بتواند پیش‌بینی دقیقی از تورم ارائه دهد، به اصلاح و بهینه‌کردن مدیریت کلان اقتصاد در کشورها از جمله ایران کمک شایان ذکری خواهد کرد و کارایی تصمیم‌سازی و سیاست‌گذاری را ارتقا خواهد بخشید. از این رو، این مقاله به دنبال انتخاب مدلی از میان مدل‌های مختلف پیش‌بینی است که بتواند پیش‌بینی دقیقی از تورم در ایران را ارائه دهد.

۲- مبانی نظری و پیشینه موضوع

پیش‌بینی‌های مدل‌محور بر اساس قاعده یا مدلی وجود می‌آیند که روابط بین متغیرهای موردنظر را مطرح می‌کنند. پیش‌بینی‌های مدل‌محور اقتصادی در اواخر دهه ۱۹۳۰ و دهه ۱۹۴۰ پدیدار شدند (Tinbergen, 1939). هدف از پیش‌بینی در این دوران آزمون نمودن ارتباط تئوری‌های اقتصادی به‌ویژه در سنتز کینزی، با استفاده از داده‌های سیستم حساب‌های ملی بود.

پیش‌بینی رفتار تورم، روشی رایج برای اقتصادهای دارای رژیم هدف‌گذاری تورم^۱ است. سیاست‌های پولی بر محیط اقتصاد کلان با تأخیر اثر می‌گذارند، اما بانک مرکزی به منظور حفظ ثبات قیمت‌ها باید همه جوانب این سیاست‌ها را در نظر بگیرد. از آنجایی که قراردادهای اسمی بلندمدت (مانند قراردادهای کار و وام مسکن) و چسبندگی قیمت از جمله ویژگی‌های معمول در اقتصاد مدرن هستند، بنابراین پیش‌بینی تورم نیز برای تصمیم‌گیری بخش خصوصی بسیار مهم است (Ferreira & Palma, 2015). با توجه به اینکه پیش‌بینی تورم یکی از مطالعات بسیار مهم در اقتصاد کلان محسوب می‌شود، روش‌های مختلفی در این خصوص ارائه شده است. شاید متداول‌ترین مطالعات تجربی در این خصوص، بر پایه منحنی فیلیپس باشد. برای نمونه آنگ^۲ و همکاران (۲۰۰۷)، اتکینسون و اوهانیان^۳ (۲۰۰۱)، گرون و همکاران^۴ (۲۰۱۰)، استاک و واتسون^۵ (۲۰۰۸، ۱۹۹۹) در این زمینه از منحنی فیلیپس استفاده نموده‌اند. هر چند جزئیات این مطالعات متفاوت است، اما چارچوب کلی آنها شامل یک متغیر وابسته مانند تورم (یا تغییرات تورم) و متغیرهای توضیحی از جمله وقفه‌های تورم، نرخ بیکاری و سایر متغیرهای پیش‌بینی‌کننده بوده است. در این راستا، روش‌های مبتنی بر رگرسیون بازگشتی تا حدودی موفق بوده‌اند (Koop & Korobilis, 2012). عملکرد محدود منحنی فیلیپس می‌تواند با بی‌ثباتی ذاتی رابطه میان تورم و بیکاری از طریق زمان توضیح داده شود (Cechetti, 1995; Dupasquier & Ricketts, 1998; Lansing, 2002).

¹ inflation targeting regime

² Ang

³ Atkeson and Ohanian

⁴ Groen

⁵ Stock and Watson

با در نظر گرفتن ادبیات پیش‌بینی در خصوص متغیر کلیدی تورم در دوره‌های زمانی مختلف، سری‌های تورم با استفاده از پراکسی‌های مختلف (مانند تورم قیمت مصرف‌کننده، شاخص ضمنی تولید ناخالص داخلی و شاخص ضمنی مخارج مصرفی شخصی) به مدل‌های ارزیابی مقایسه‌ای^۶ مختلفی متکی هستند. تعداد زیادی از مطالعات تأکید می‌کنند که عملکرد پیش‌بینی یک مدل خاص به دوره نمونه و افق پیش‌بینی، حساس است. عملکرد مرحله‌ای مدل‌های تورم می‌تواند به بی‌ثباتی میان تورم و متغیرهای پیش‌بینی‌کننده آن ارتباط داشته باشد (Atkeson & Ohanian, 2001). این بی‌ثباتی نشان می‌دهد که مدل‌های تورم وابسته به وجود شکست‌های ساختاری هستند. در واقع بسیاری از مقالات (Fisher, Liu & Zhou., 2002; Canova, 2007) مطرح می‌کنند که پارامترها در رابطه بین تورم و متغیرهای پیش‌بینی‌کننده آن بی‌ثبات^۷ هستند و ممکن است در طول زمان تغییر کنند. علاوه بر این، مطالعات مختلفی (Cechetti, Chu & Steindel, 2000; Stock & Watson, 2008; Brave & Fisher, 2004; Watson, 2003) نشان دادند که متغیرهای پیش‌بینی‌کننده تورم ممکن است در برخی دوره‌های زمانی به تورم مرتبط باشند یا نباشند.

سه موضوع در هنگام استفاده از روش‌های پیش‌بینی تورم وجود دارد. اول اینکه ضرایب متغیرهای پیش‌بینی‌کننده تورم می‌توانند در طول زمان تغییر کنند. به‌گونه‌ای که معمولاً تصور می‌شود شیب منحنی فیلیپس در طول زمان تغییر می‌کند. اگر چنین باشد؛ ضرایب متغیرهای پیش‌بینی‌کننده‌ای که این شیب را تعیین می‌کنند، تغییر خواهند کرد. در سطحی وسیع‌تر، ادبیات گسترده‌ای در اقتصاد کلان وجود دارد که شکست‌های ساختاری و انواع دیگری از تغییر پارامتر را در بسیاری از متغیرهای سری زمانی مطرح کرده‌اند (Stock & Watson, 1996). دوم اینکه تعداد متغیرهای پیش‌بینی‌کننده بالقوه می‌تواند زیاد باشد. گرون و همکاران^۸ (۲۰۱۰) ده متغیر پیش‌بینی‌کننده تورم را در نظر گرفتند. محققانی که با مدل‌های عاملی کار می‌کنند، مانند استاک و واتسون (۱۹۹۹) به طور معمول تعداد بیشتری از این متغیرها را در نظرمی‌گیرند. وجود تعداد بسیاری از متغیرهای پیش‌بینی‌کننده تورم منجر به تعداد زیادی از مدل‌ها می‌شود. اگر m پیش‌بینی‌کننده بالقوه وجود داشته باشد،

⁶ benchmark

⁷ unstable

⁸ Groen

محقق 2^m مدل دارد. این امر مشکلات آماری اساسی را برای انتخاب مدل ایجاد می‌کند. مطالعات آوراموو (۲۰۰۲)، کرمرز (۲۰۰۲) و کوپ و پوتر (۲۰۰۴) نمونه‌هایی از این مطالعات در اقتصاد کلان و امور مالی هستند (Avramov, 2002; Cremers, 2002; Koop & Potter, 2004).

سوم اینکه مدل مربوط به پیش‌بینی می‌تواند بطور بالقوه‌ای در طول زمان تغییر کند. متغیرهای پیش‌بینی‌کننده تورم ممکن است در سیکل‌های رکود و رونق متفاوت باشند. به عبارتی دیگر، برخی از متغیرها ممکن است در دوران رکود به خوبی تورم را پیش‌بینی کنند و در دوران رونق از عملکرد مناسبی برای پیش‌بینی برخوردار نباشند. علاوه بر این، استاک و واتسون (۲۰۰۸) دریافتند که پیش‌بینی‌های منحنی فیلیپس در برخی از دوره‌ها به خوبی عمل می‌کنند، اما در دوره‌های دیگر استراتژی‌های پیش‌بینی تک متغیره، بهتر عمل می‌کنند. پسران و تیمرمن (۲۰۰۵) در مطالعه‌ای نشان دادند که متغیرها به صورت کارا و مفیدی برای پیش‌بینی بازده سهام در طول زمان تغییر می‌کنند. چنین استدلال‌هایی نشان می‌دهد که مدل پیش‌بینی در طول زمان در حال تغییر است. لازم به ذکر است، این نوع موضوعات بسیار پیچیده می‌باشند و اقتصادسنجی دشواری را می‌طلبد (Pesaran & Timmermann, 2005).

علاوه بر این، مدل‌های پارامتر متغیر در طول زمان (TVP)، روش‌های فضا حالت (مانند فیلتر کالمن) را بکار می‌گیرند که این امر 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 شود، مدل‌های TVP تمایل به بیش‌برازشی^۹ در داخل نمونه دارند، لذا عملکرد پیش‌بینی ضعیفی در خارج از نمونه خواهند داشت. برای تصحیح این کاستی‌ها در مدل‌های TVP، از الگوی متوسط‌گیری پویا (DMA) و برای الگوی گزینشی‌نمودن الگوی پویا (DMS) استفاده شده است (Gupta, Hammoudeh, Kim & Simo-Kengne, 2014). در مطالعه کوپ و کوروبلیس (۲۰۱۲) از رویکرد DMA/DMS برای پیش‌بینی تورم در کشور آمریکا بکار برده شده است. از این رویکرد برای پیش‌بینی قیمت‌های آینده بازارهای کربنی (Koop & Tole, 2012)، نرخ‌های ارز (Buncic & Frey, 2012; De Bruyn, Gupta &)

⁹ over-fit

Nicoletti & Passaro, 2013) و پویایی‌های رشد تولید ناخالص داخلی (van Eyden, 2013) نیز استفاده شده‌است (Filippo, 2015). اما به طور کلی مزیت اصلی^{۱۰} DMA/DMS در مورد مدلسازی آن است که 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.

۳- روش‌شناسی تحقیق

مدل‌های پارامتر متغیر در طول زمان معمولاً با روش‌های فضا-حالت مانند فیلتر کالمن تخمین زده می‌شوند. مدل‌های فضا-حالت با مدل‌های سری زمانی پویایی که شامل متغیرهای غیرقابل مشاهده هستند، سرو کار دارد (Kim & Nelson, 1998). ابزار اصلی به منظور برآورد مدل‌های فضا-حالت استاندارد، فیلتر کالمن است. فیلتر کالمن یک فرآیند بازگشتی برای محاسبه تخمین زنده‌های مؤلفه‌های غیرقابل مشاهده یا بردار حالت در زمان t است که بر اساس تمام اطلاعات موجود تا زمان t است. مدل‌های فضا-حالت از دو معادله معادله اندازه‌گیری و معادله وضعیت تشکیل شده‌اند. مدل‌های فضا-حالت می‌توانند به صورت زیر بیان شوند:

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

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

به طوری که معادله (۱) معادله اندازه‌گیری و معادله (۲) معادله وضعیت می‌باشند. y_t متغیر وابسته پیش‌بینی است، $Z_t = [1, z_{1,t-1}, z_{2,t-1}, \dots, z_{m,t-1}]$ یک بردار $(1 \times m)$ از مشاهدات متغیرهای توضیحی (پیش‌بینی‌کننده‌ها) است که برای پیش‌بینی y_t مورد استفاده قرار می‌گیرند. $\theta_t = [\theta_{0,t-1}, \theta_{1,t-1}, \theta_{2,t-1}, \dots, \theta_{m,t-1}]$ یک بردار $(m \times 1)$ از ضرایب (وضعیت) است. ε_t و η_t جملات خطای دارای توزیع نرمال و مستقل هستند به طوری که $\varepsilon_t \sim N(0, H_t)$ است و $\eta_t \sim N(0, Q_t)$ است که H_t و Q_t به ترتیب

¹⁰. Dynamic Model Selection

ماتریس واریانس و کوواریانس معادله اندازه‌گیری و وضعیت هستند. معادله (۱) رابطه میان متغیرهای قابل مشاهده (متغیرهای برونزا) و متغیرهای وضعیت غیرقابل مشاهده را نشان می‌دهد. معادله (۲) پویایی‌های متغیرهای وضعیت را بیان می‌کند. فرض می‌شود که متغیرهای وضعیت از گام تصادفی پیروی می‌کنند. مدل‌های (۱) و (۲) اجازه می‌دهند که ضرایب در طول زمان تغییر کنند. ولیکن این مدل اجازه نمی‌دهد که متغیرهای پیش‌بینی‌کننده در طول زمان تغییر کنند. راه‌حل این مسئله، استفاده از رویکرد DMA است. مجموعه‌ای از K مدل که شامل زیرمجموعه‌های مختلفی از متغیرهای پیش‌بینی‌کننده Z_t است را در نظر بگیرید.

$$y_t = Z_t^{(k)} \theta_t^{(k)} + \varepsilon_t^{(k)} \quad (۳)$$

$$\theta_{t+1}^{(k)} = \theta_t^{(k)} + \eta_t^{(k)}, \quad (۴)$$

که در آن $\varepsilon_t^{(k)} \sim N(0, H_t^{(k)})$ و $\eta_t^{(k)} \sim N(0, Q_t^{(k)})$ است. $L_t \in \{1, 2, \dots, K\}$ نشان‌دهنده تمام مدل‌های ممکن در هر نقطه از زمان است. $L_t = k$ به معنی آن است 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 انتخاب‌شده در طول زمان می‌تواند تغییر کند. در هر زمان $t = 1, 2, \dots, T$ ، DMA و DMS با محاسبه $\Pr(L_t = k | Y^{t-1})$ برای $k = 1, \dots, K$ به طوری که $Y^{t-1} = \{y_1, \dots, y_{t-1}\}$ 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 $fork = 1, \dots, K$ را به عنوان وزن‌های مدل برای

محاسبه میانگینی از K مدل پیش‌بینی استفاده می‌کند^{۱۱} (Cogley & Sargent, 2005; Cogley, Morozov & Sargent, 2005; Primiceri, 2005).

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. یکی از محدودیت‌های این رویکرد آن است که مدل‌ها می‌توانند پارامترهای بسیار زیادی داشته باشند که برآورد و پیش‌بینی آنها زمان بسیاری را صرف می‌کند. در حقیقت، با m متغیر پیش‌بینی کننده بالقوه، DMA/DMS به تعداد 2^m مدل در هر نقطه از زمان برآورد می‌شود. اگر مدل‌های پیش‌بینی متفاوت در هر نقطه از زمان بکارگرفته شوند، تعداد مدل‌های ترکیبی که باید برای پیش‌بینی برآورد شود در زمان \bar{T} برابر با $2^{m\bar{T}}$ خواهد شد. به منظور مقابله با این مشکل، رافتری و همکاران^{۱۲} (۲۰۱۰، ۲۰۰۷) تقریب‌هایی مبتنی بر روش‌های فضا-حالت با فیلتر کالمن پیشنهاد دادند. این تقریب‌ها شامل دو پارامتر λ و α هستند که به عنوان عوامل فراموش‌شده^{۱۳} مطرح می‌باشند. پارامترهای λ و α اعدادی کوچک‌تر اما نزدیک به یک هستند. عامل فراموش‌شده λ در معادله وضعیت برای پارامترها و عامل فراموش‌شده α در معادله وضعیت برای مدل‌ها استفاده شده است. فیلتر کالمن شامل دو مرحله پیش‌بینی^{۱۴} و مرحله به‌روزرسانی می‌باشد.

یک جنبه از الگوریتم رافتری و همکاران (۲۰۰۷) عدم نیاز به استفاده از زنجیره مارکف مونت کارلو (MCMC) در هر مدل انفرادی است. آنها این کار را برای دستیابی به تخمین جایگزینی^{۱۵} از H_t و فرض $Q_t = (1 - \lambda^{-1}) \sum_{i=1}^t H_i$ انجام می‌دهند، به طوری که $0 < \lambda \leq 1$ و \sum_t ماتریس کوواریانس خطای تخمین در فیلتر کالمن است. به‌طور کلی، می‌توان $\pi_{i|t-1,k}$ را در یک روش تکرارشونده بدست آورد. بنابراین:

^{۱۱}. رافتری، کارنی و اتلر (۲۰۱۰) بر DMA در یک برنامه صنعتی تمرکز کردند، در حالی که کوپ و کورویلیس (۲۰۱۲) هر دوی روش‌های DMA و DMS را برای پیش‌بینی تورم استفاده نموده‌اند.

^{۱۲} Raftery

^{۱۳} forgetting factors

^{۱۴} prediction step

^{۱۵} plug-in

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

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

$$\pi_{t|t-1,k} = \frac{\pi_{t-1|t-1,k}^\alpha}{\sum_{l=1}^K \pi_{t-1|t-1,l}^\alpha} \quad (6)$$

به طوری که $0 < \alpha \leq 1$ یکی دیگر از عوامل فراموش شده است که تفسیر آن مشابه λ است، اما در آن بجای تکامل پارامترها، تکامل مدل‌ها مطرح است. زمانی که داده‌ها در فرکانس نسبتاً بالایی هستند، می‌توان انتظار داشت که پارامترها و متغیرهای پیش‌بینی‌کننده، بطور نسبی مکرراً تغییر یابند. این امر به معنی آن است که ممکن است مقادیر λ ، α نزدیک به 1^{17} پیش‌بینی‌های بهینه‌ای نداشته باشند. با توجه به اینکه هیچ آگاهی در ادبیات در خصوص بهترین مقادیر α و λ وجود ندارد، رافتی و همکاران (۲۰۱۰)، مقادیر ۰٫۹۹ را پیشنهاد داده‌اند. علاوه بر این، کوپ و کورویلیس (۲۰۱۱، ۲۰۱۲) بین مقادیر ۰٫۹۳ و ۱ بررسی‌هایی را به منظور یافتن بهترین مقادیر انجام دادند و بهترین مقدار را برای پیش‌بینی تورم آمریکا ۰٫۹۹ در نظر گرفته‌اند (Naser & Alaali, 2015). گراسی و سانتوسی دی ماگیستریس^{۱۷} (۲۰۱۵) مقادیر α و λ را بر مبنای عملکرد پیش‌بینی انتخاب نموده‌اند، اما این مقادیر نتایج DMA را تورش‌دار می‌کند و بنابراین فرآیند خارج از نمونه‌ای پیش‌بینی نامعتبر می‌شود (Koop & Korobilis, 2011). بنابراین با استفاده از مجموعه‌ای از مقادیر λ ، α در یک نمونه از آموزش‌های اولیه پیش‌بینی صورت می‌گیرد و سپس مقادیر ترکیبی بهینه انتخاب می‌شوند که برخی از آنها

^{۱۶}. به عنوان مثال، در مقاله کوپ و کورویلیس (۲۰۰۹) مقدار پیش فرض $\alpha = \lambda = 0.99$ برای داده‌های کلان فصلی پیشنهاد شده است.

^{۱۷}. Grassi & Santucci de Magistris

بیانگر آن است که تمامی متغیرها فاقد هر گونه ریشه واحد با تناوب فصلی و نیم‌سالانه بوده ولیکن دارای ریشه واحد غیرفصلی می‌باشند. به گونه‌ای که، اگر $z_{i,t}$ سری‌های غیرتبدیلی اصلی^{۱۸} 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 $x_{i,t} = \ln z_{i,t} - \ln z_{i,t-1}$ ؛ ۶- لگاریتم با دو مرتبه تفاضل‌گیری $x_{i,t} = \ln z_{i,t} - \ln z_{i,t-2}$. در نهایت تمام متغیرها با تفاضل از میانگین و تقسیم بر انحراف معیار، استانداردسازی شده‌اند. فهرست کامل متغیرها به همراه درجه ایستایی آنها در پیوست مقاله ارائه شده‌است.

از تحلیل مؤلفه‌های اساسی برای استخراج عوامل با استفاده از تمامی متغیرها در هر بلوک استفاده شده است. علاوه بر این، وقفه‌های هر مدل با استفاده از BIC تعیین شده‌اند. همانند مطالعه کوپ و کورویلیس (۲۰۱۲) پیش‌بینی با سه افق در نظر گرفته شده است: افق کوتاه‌مدت یعنی یک فصل جلوتر ($h = 1$)، افق میان‌مدت یعنی چهار فصل جلوتر ($h = 4$) و افق بلندمدت یعنی هشت فصل جلوتر ($h = 8$).

۵- ارزیابی عملکرد پیش‌بینی رویکردهای DMA/DMS

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:

¹⁸ original untransformed series

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

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

به طوری که $f_t^{(b)}$ نشان‌دهنده عامل استخراج‌شده از b امین بلوک متغیرهای پیش‌بینی‌کننده و θ_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. همان‌طور که مطرح شد، عامل‌ها از طریق روش مؤلفه‌های اساسی^{۱۹} 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 و همچنین یک وقفه ($p_y = 1$) از متغیر وابسته و عرض از مبدأ منظور می‌شود. این استراتژی منجر به m پیش‌بینی‌کننده بالقوه و $k = 2^m$ مدل می‌شود. با در نظر گرفتن فروض ذیل، تعداد مدل‌ها کاهش می‌یابند: (۱) تمام مدل‌ها حاوی عرض از مبدأ و وقفه‌های متغیر وابسته هستند و (۲) در مدل‌های مورد نظر بایستی هم عامل و هم وقفه آن حضور داشته باشند، در غیر این صورت مدل مورد نظر حذف می‌شود. با این فرضیات تعداد مدل‌ها کاهش می‌یابد. با این فرضیات و در نظر گرفتن نه بلوک عاملی،^{۲۹} مدل (۵۱۲ مدل ممکن) در هر لحظه از زمان وجود دارد. همانند مطالعات صورت گرفته در این زمینه، مدل‌های DMA/DMS با استفاده از عوامل فراموش شده متفاوت برای α و λ به منظور بررسی حساسیت نتایج به تغییر در عوامل فراموش شده به شرح زیر در نظر گرفته شد:

- **DMA1/DMS1:** TVP_AR(1)_X DMA/DMS ($\alpha = \lambda = 0.99$)
- **DMA2/DMS2:** TVP_AR(1)_X DMA/DMS ($\alpha = \lambda = 0.95$)
- **DMA3/DMS3:** TVP_AR(1)_X DMA/DMS ($\alpha = \lambda = 0.9$)

که به عنوان مثال در آن منظور از مدل TVP_AR(1)_X DMA، مدل DMA حاوی یک وقفه متغیر وابسته (AR(1)) به همراه نه بلوک عاملی (-X) می‌باشد و علاوه بر این ضرایب مدل در طول زمان تغییر خواهند کرد (TVP). هر چه λ به یک نزدیک‌تر باشد، ثبات

¹⁹ Principal Components

بیشتری در ضرایب یک مدل معین در طول زمان وجود دارد. هر چه α به یک نزدیک‌تر باشد، ثبات بیشتری در ترکیب یک مدل معین در طول زمان وجود دارد. پیش‌بینی‌ها با استفاده از DMA و DMS بصورت زیر می‌باشد:

$$DMA: y_{t+h/t}^f = \sum_{k=1}^K \pi_{t+h/t,k} z_{t+h}^{(k)} \hat{\theta}_t^{(k)} \quad \text{with } k = 1, \dots, K$$

$$DMS: y_{t+h/t}^f = \text{Max}_{\arg(k)} \left\{ \pi_{t+h/t,k} \right\} z_{t+h}^{(k)} \hat{\theta}_t^{(k)} \quad \forall k = 1, \dots, K$$

علاوه بر این، رویکرد DMA بدون هیچ وزن فراموش شده‌ای بر ضرایب زمان متغیر ($\lambda = 1$) در نظر گرفته شده است:

$$DMA \ 4: TVP_AR(1)_X \text{ DMA } (\alpha = 0.95 \quad \lambda = 1)$$

$$DMA \ 5: TVP_AR(1)_X \text{ DMA } (\alpha = 0.99 \quad \lambda = 1)$$

همانند مطالعه کوپ و کورویلیس (۲۰۱۲) و فیلیپو (۲۰۱۵)، روش‌های بالا با یک روش BMA که حالت خاصی از DMA با ($\alpha = \lambda = 1$) است، مقایسه شد. BMA مدلی است که هیچ وزن فراموش‌شده‌ای بر احتمالات منتسب به مدل ($\alpha = 1$) و هیچ وزن فراموش‌شده‌ای بر ضرایب زمان متغیر ($\lambda = 1$) ندارد. به عبارت دیگر، تمام خطاهای گذشته در به‌روزرسانی ضرایب تخمینی و احتمالات پسین، بطور مساوی وزن داده شده‌اند. بنابراین:

$$BMA: \alpha = \lambda = 1$$

علاوه بر رویکردهای ارائه‌شده در بالا، پیش‌بینی تورم شاخص قیمت مصرف‌کننده با مدل‌های خودرگرسیون برداری بیزین (BVAR)، پارامتر متغیر در طول زمان TVP، خودرگرسیو AR(1) OLS و AR(1)_X OLS مقایسه شده‌اند:

۱- با استفاده از شش متغیر نرخ بیکاری، تولید ناخالص داخلی، نرخ ارز، قیمت نفت سنگین، شاخص کل بورس، نقدینگی مدل خودرگرسیون برداری بیزی (BVAR) به منظور پیش‌بینی

نرخ تورم مصرف‌کننده برآورد شد. به همین منظور از مدل BVAR با تابع پیشین، Minnesota استفاده شده است. انتخاب توابع پیشین همانند مطالعه کوپ و کورویلیس (۲۰۱۰) و بالیسار و همکاران (۲۰۱۸) بوده است.

۲- سپس از مدل‌های پارامتر متغیر در طول زمان TVP-AR(1) با عامل فراموش شده استفاده شد که در آن از شاخص قیمت مصرف‌کننده با وقفه به عنوان متغیر مستقل در نظر گرفته شده است. در این مطالعه از دو عامل فراموش شده $\lambda = 0.99$ و $\lambda = 0.95$ بهره گرفته شده است. به طوری که با عامل فراموش شده $\lambda = 0.99$ ، ضرایب حرکت نسبتاً آرامی دارند که انتخاب این عامل فراموش شده همانند مطالعه کوپ و کورویلیس (۲۰۱۲، ۲۰۱۱)؛ فریرا و پالما (۲۰۱۵)؛ باونسیکا و مورتوب^{۲۱} (۲۰۱۵) و ناصر و علائی (۲۰۱۸) می‌باشد و عامل فراموش شده $\lambda = 0.95$ که در آن ضرایب دارای حرکت سریعی هستند که انتخاب این عامل فراموش شده همانند مطالعه کوپ و کورویلیس (۲۰۱۲، ۲۰۱۱) بوده است.

۳- در نهایت از دو مدل AR(1) به روش OLS استفاده شده است. به طوری که در مدل AR(1)-X از تمام نه بلوک عاملی (-X) و وقفه متغیر وابسته (AR(1)) تشکیل شده و در مدل AR(1) تنها از وقفه متغیر وابسته همانند مطالعه کوپ و کورویلیس (۲۰۱۲، ۲۰۱۱) استفاده شده است.

۲-۵- بررسی عملکرد پیش‌بینی

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 ۱ تا

جدول ۳ بیانگر آماره‌های خطای پیش‌بینی برای افق‌های پیش‌بینی یک فصل، چهار فصل و هشت فصل جلوتر می‌باشد. از نظر MAFE و MAPE (جدول ۱) بهترین پیش‌بینی‌ها

²⁰ Balcilar

²¹ Buncica & Morettob

در افق‌های زمانی مختلف به ترتیب عبارتند از DMS3 و TVP1 در افق کوتاه‌مدت ($h = 1$) ،
DMA3 و DMA4 در افق میان‌مدت ($h = 4$) و DMS3 در افق بلندمدت ($h = 8$) .

جدول ۱. معیارهای عملکرد پیش‌بینی MAFE، MAPE در افق‌های پیش‌بینی مختلف
مأخذ: محاسبات تحقیق

Table 1. Forecast performance MAFE, MAPE for h-step-ahead

Source: Research calculations

مدل	معیار	افق پیش‌بینی		
		۱	۴	۸
DMA1:TVP-AR-DMA ($\alpha = \lambda = 0.99$)	MAFE	۰/۳۸۴۱	۰/۳۹۱۵	۰/۳۹۲۶
	MAPE	۱/۷۳۷	۲/۰۸۶	۲/۰۹۳
DMA2:TVP-AR-DMA ($\alpha = \lambda = 0.95$)	MAFE	۰/۳۶۰۴	۰/۳۵۹۱	۰/۳۵۶۱
	MAPE	۱/۷۸۲	۲/۱۳	۱/۹۸۲
DMA3:TVP-AR-DMA ($\alpha = \lambda = 0.9$)	MAFE	۰/۳۲۴	۰/۳۲۶	۰/۳۲۹
	MAPE	۱/۶۴۲	۲/۱۷۵	۱/۹۸۱
DMS1:TVP-AR-DMS ($\alpha = \lambda = 0.99$)	MAFE	۰/۳۹۴	۰/۴۱۶۶	۰/۴۴۴۸
	MAPE	۱/۸۶۲۲	۲/۴۱۷۸	۲/۵۱۸۸
DMS2:TVP-AR-DMS ($\alpha = \lambda = 0.95$)	MAFE	۰/۳۴۷۸	۰/۳۶۱۷	۰/۳۶۹۸
	MAPE	۱/۶۳۹۳	۲/۶۳۲۵	۲/۴۰۵۵
DMS3:TVP-AR-DMS ($\alpha = \lambda = 0.9$)	MAFE	۰/۲۹۸۱	۰/۳۵۱۰	۰/۳۰۰۰
	MAPE	۱/۶۴۰۵	۲/۵۱۲۰	۱/۹۷۳۹
DMA4:TVP-AR-DMA ($\alpha = 0.99, \lambda = 1$)	MAFE	۰/۳۸۳۶	۰/۳۹۴۶	۰/۴۰۳۴
	MAPE	۱/۶۳۳۷	۱/۹۷۶۲	۲/۵۰۸۰
DMA5:TVP-AR-DMA ($\alpha = 0.95, \lambda = 1$)	MAFE	۰/۳۴۱۲	۰/۳۵۲۸	۰/۳۶۵۱
	MAPE	۱/۴۷۶۸	۲/۱۰۳۳	۱/۹۹۳۱
TVP-AR-BMA ($\alpha = \lambda = 1$)	MAFE	۰/۳۹۹۴	۰/۴۱۸۳	۰/۴۱۸۷
	MAPE	۱/۹۶۱۹	۲/۴۴۰۶	۲/۵۸۹۹
TVP1:TVP-AR ($\lambda = 0.99$)	MAFE	۰/۴۸۲۱	۰/۴۸۶۰	۰/۴۹۹۶
	MAPE	۱/۴۲۵۰	۶/۱۴۱۸	۲/۲۵۰۱
TVP2:TVP-AR ($\lambda = 0.95$)	MAFE	۰/۴۶۷۷	۰/۴۵۹۹	۰/۴۶۱۷
	MAPE	۱/۶۴۳۸	۵/۲۱۸۶	۱/۶۴۱۹
<i>BVAR – Minnesota</i>	MAFE	۱/۱۳۸	۱/۰۵۵۲	۱/۱۷۹۶
	MAPE	۶/۹۴۹۹	۲/۵۶۷۷	۴/۲۱۲۸
AR(1) – X (OLS)	MAFE	۰/۵۳۸۲	۰/۵۴۲۱	۰/۵۵۱۸
	MAPE	۲/۱۳۹۶	۳/۲۶۷۴	۲/۷۰۲۷
AR(1)(OLS)	MAFE	۰/۶۲۵۶	۰/۶۳۰۸	۰/۶۳۹۸
	MAPE	۲/۵۵۵	۳/۸۵۴۲	۲/۵۰۰۱

جدول ۲ ارائه‌دهنده MSFE، Bias و FEV می‌باشد. با توجه به نتایج بدست‌آمده در افق پیش‌بینی کوتاه‌مدت ($h = 1$) مدل DMS3، در افق پیش‌بینی میان‌مدت ($h = 4$) مدل DMS2 و در افق پیش‌بینی بلندمدت ($h = 8$) از منظر MSFE و FEV مدل DMS3 و بر اساس Bias مدل پیش‌بینی DMS2 بهینه بوده‌اند.

جدول ۲. معیارهای عملکرد پیش‌بینی MSFE، Bias و FEV در افق‌های پیش‌بینی مختلف
مأخذ: محاسبات تحقیق

Table 2. Forecast performance MSFE, Bias, FEV for h-step-ahead

Source: Research calculations

مدل	معیار	افق پیش‌بینی		
		۱	۴	۸
<i>DMA1: TVP-AR-DMA</i> ($\alpha = \lambda = 0.99$)	MSFE	۰/۲۶۷۵	۰/۲۸۳۷	۰/۳۱۶۱
	Bias	۰/۰۶۶۶	۰/۰۲۰۱	۰/۰۰۸۶
	FEV	۰/۲۶۳۰	۰/۲۸۳۳	۰/۳۱۶۰
<i>DMA2: TVP-AR-DMA</i> ($\alpha = \lambda = 0.95$)	MSFE	۰/۲۶۷۴	۰/۲۶۲۰	۰/۲۶۵۴
	Bias	-۰/۰۱۹	-۰/۰۰۹۵	-۰/۰۱۵۲
	FEV	۰/۲۶۷۱	۰/۲۶۱۹	۰/۲۶۵۲
<i>DMA3: TVP-AR-DMA</i> ($\alpha = \lambda = 0.9$)	MSFE	۰/۲۲۶۲	۰/۲۳۰۷	۰/۲۴۴۶
	Bias	-۰/۰۱۸۷	-۰/۰۱۰۶	-۰/۰۰۸۹
	FEV	۰/۲۲۵۸	۰/۲۳۰۶	۰/۲۴۴۵
<i>DMS1: TVP-AR-DMS</i> ($\alpha = \lambda = 0.99$)	MSFE	۰/۲۷۴۹	۰/۲۸۷۷	۰/۴۳۵۷
	Bias	۰/۰۸۵۸	۰/۰۲۳۱	-۰/۰۰۳۹
	FEV	۰/۲۶۷۵	۰/۲۸۷۱	۰/۴۳۵۷
<i>DMS2: TVP-AR-DMS</i> ($\alpha = \lambda = 0.95$)	MSFE	۰/۲۰۲۴	۰/۲۰۵۶	۰/۲۲۱۵
	Bias	-۰/۰۱۱۷	-۰/۰۰۵۵	-۰/۰۰۵۴
	FEV	۰/۲۰۲۳	۰/۲۰۵۶	۰/۲۲۱۴
<i>DMS3: TVP-AR-DMS</i> ($\alpha = \lambda = 0.9$)	MSFE	۰/۱۳۹۸	۰/۲۷۰۶	۰/۱۸۵۰
	Bias	-۰/۰۰۶۷	-۰/۰۰۶۴	-۰/۰۳۵۲
	FEV	۰/۱۳۹۸	۰/۲۶۶۸	۰/۱۸۳۸
<i>DMA4: TVP-AR-DMA</i> ($\alpha = 0.99, \lambda = 1$)	MSFE	۰/۲۶۸۳	۰/۲۸۳۴	۰/۲۹۳۵
	Bias	۰/۰۵۳۵	۰/۰۲۴۰	۰/۰۳۱۱
	FEV	۰/۲۶۵۴	۰/۲۸۲۹	۰/۲۹۲۵
	MSFE	۰/۲۰۱۷	۰/۲۱۲	۰/۲۲۷۶

<i>DMA5 : TVP - AR - DMA</i> ($\alpha = 0.95, \lambda = 1$)	Bias	۰/۰۲۱	۰/۰۲۰۹	۰/۰۳۶۵
	FEV	۰/۲۰۱۲	۰/۲۰۹۸	۰/۲۲۶۳
	MSFE	۰/۲۹۳۵	۰/۳۲۳۲	۰/۳۱۹۴
<i>TVP - AR - BMA</i> ($\alpha = \lambda = 1$)	Bias	۰/۰۸۱۲	۰/۰۲۷۸	۰/۰۱۹۸
	FEV	۰/۲۸۶۹	۰/۳۱۲۴	۰/۳۱۹۰
	MSFE	۰/۶۱۳۷	۰/۵۷۹۱	۰/۶۰۵۵
<i>TVP1 : TVP - AR</i> ($\lambda = 0.99$)	Bias	-۰/۲۰۲۹	-۰/۱۸۳۲	-۰/۲۹۰۴
	FEV	۰/۵۷۲۶	۰/۵۴۵۶	۰/۵۲۱۱
	MSFE	۰/۶۰۶۹	۰/۵۶۹۲	۰/۵۴۹۶
<i>TVP2 : TVP - AR</i> ($\lambda = 0.95$)	Bias	-۰/۱۴۴	-۰/۱۲۸	-۰/۱۴۳۵
	FEV	۰/۵۸۶۲	۰/۵۵۲۹	۰/۵۲۹۰
	MSFE	۲/۱۰۵۳	۱/۸۳۹۸	۲/۴۰۲۱
<i>BVAR - Minnesota</i>	Bias	۰/۷۹	۰/۴۴۳۴	۰/۸۱۶۳
	FEV	۱/۴۸۱۲	۱/۶۴۳۲	۱/۷۳۵۸
	MSFE	۰/۵۹۵۶	۰/۶۰۶۰	۰/۶۲۴۴
<i>AR(1) - X (OLS)</i>	Bias	-۰/۰۶۰۷	-۰/۰۵۴۲	-۰/۰۶۰۵
	FEV	۰/۵۹۱۹	۰/۶۰۳۱	۰/۶۲۰۷
	MSFE	۰/۶۲۳۰	۰/۶۳۳	۰/۶۴۸۸
<i>AR(1)(OLS)</i>	Bias	-۰/۳۱۶۱	-۰/۳۱۰۲	-۰/۳۱۴۰
	FEV	۰/۵۲۳۱	۰/۵۳۶۷	۰/۵۵۰۳

در خصوص مقایسه مدل‌های TVP_AR همان‌طور که مشاهده می‌شود مدل TVP1 بر اساس معیار FEV در تمامی افق‌های پیش‌بینی دارای عملکرد بهتری بوده و در افق پیش‌بینی کوتاه‌مدت بنا بر معیار MAPE مدل TVP1 دارای عملکرد بهتری بوده و لیکن در سایر معیارهای پیش‌بینی و تمامی افق‌های پیش‌بینی مورد بررسی، مدل TVP2 دارای عملکرد بهتری نسبت به مدل TVP1 بوده 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 بهتری نسبت به مدل BMA می‌باشد؛ این امر نشان می‌دهد که هر دوی تغییرات در پارامترها و مدل‌ها دارای عملکرد بهتری در پیش‌بینی هستند.

مدل BVAR تقریباً در تمامی افق‌های پیش‌بینی دارای ضعیف‌ترین عملکرد نسبت به سایر مدل‌های مورد استفاده بوده است. در خصوص مقایسه مدل‌های AR(1) و AR(1)-X OLS



OLS آن که در اکثر معیارها و افق‌های پیش‌بینی، مدل AR(1)-X OLS دارای عملکرد بهتری نسبت به AR(1) OLS بوده‌است. 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 گزینشی‌نمودن الگوی پویا با استفاده از برآورد دقیق مبتنی بر احتمال^{۲۲} مدل‌های TVP با عوامل بلوکی، استراتژی بهینه‌ای است. از سویی دیگر، نتایج حاصل از MSFE، MAPE، MAFE، FEV و BIAS نسبت به احتمال‌های پیش‌بینی قوی نیستند و تفاوت‌هایی دارند. دلیل این امر آن است که این معیارها، تنها از پیش‌بینی‌های نقطه‌ای^{۲۳} استفاده می‌کنند، در حالی که احتمال‌های پیش‌بینی از کل توزیع پیش‌بینی‌کننده 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 $TVP-AR-DMS(\alpha = \lambda = 0.9)$ مدل بهینه‌ای است.

جدول ۳. معیار عملکرد پیش‌بینی LOG(PL) در افق‌های پیش‌بینی مختلف
مأخذ: محاسبات تحقیق

Table ۳. Forecast performance LOG(PL) for h-step-ahead

Source: Research calculations

مدل	افق پیش‌بینی		
	۱	۴	۸
$TVP-AR-DMA(\alpha = \lambda = 0.99)$	-۶۶/۳۵	-۶۵/۸۱	-۶۱/۹۵
$TVP-AR-DMA(\alpha = \lambda = 0.95)$	-۶۱/۸۷	-۶۱/۴۱	-۵۶/۳۷
$TVP-AR-DMA(\alpha = \lambda = 0.9)$	-۶۰/۵۵	-۵۹/۴۷	-۵۶/۹۱
$TVP-AR-DMS(\alpha = \lambda = 0.99)$	-۶۵/۶۷	-۶۵/۳	-۶۱/۴
$TVP-AR-DMS(\alpha = \lambda = 0.95)$	-۴۹/۵۸	-۴۸/۷۷	-۴۷/۴۹
$TVP-AR-DMS(\alpha = \lambda = 0.9)$	-۳۵/۴	-۳۹/۵۵	-۳۴/۱۱
$TVP-AR-DMA(\alpha = 0.99, \lambda = 1)$	-۶۷/۱	-۶۶/۶۵	-۶۵/۷۳
$TVP-AR-DMA(\alpha = 0.95, \lambda = 1)$	-۶۰/۷۲	-۶۰/۵۵	-۶۲/۶۰
$TVP-AR-BMA(\alpha = \lambda = 1)$	-۷۰/۱۳	-۶۸/۹۵	-۶۷/۱۶

²² likelihood-based estimation

²³ point forecasts

علاوه بر این، به منظور مقایسه صحت پیش‌بینی از آزمون دیبولد-ماریانو^{۲۴} (۱۹۹۵) استفاده شد. این آزمون، قدرت پیش‌بینی را تحت فرض برابری قدرت پیش‌بینی دو مدل بررسی می‌کند. نتایج این آزمون در جدول زیر ارائه شده است.

جدول ۴. نتایج آزمون دیبولد-ماریانو
مأخذ: محاسبات تحقیق

Table ۴. results of Diebold-Mariano Test

Source: Research calculations

نتیجه	آماره	معیار MSE	فرض
عدم رد برابر بودن قدرت پیش‌بینی دو مدل	۰/۳۱۰۹ (۰/۷۵۵۹)	$DMA(\alpha = \lambda = 0.95)$ دارای پیش‌بینی بهتری است	در $DMA(\alpha = \lambda = 0.99)$ مقابل $DMA(\alpha = \lambda = 0.95)$
عدم رد برابر بودن قدرت پیش‌بینی دو مدل	۱/۶۴ (۰/۱۰۱۰)	$DMA(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMA(\alpha = \lambda = 0.99)$ مقابل $DMA(\alpha = \lambda = 0.9)$
رد برابر بودن قدرت پیش‌بینی دو مدل	۴/۳۶۷ (۰/۰۰۰)	$DMA(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMA(\alpha = \lambda = 0.95)$ مقابل $DMA(\alpha = \lambda = 0.9)$
رد برابر بودن قدرت پیش‌بینی دو مدل	۳/۳۷۴ (۰/۰۰۰)	$DMS(\alpha = \lambda = 0.95)$ دارای پیش‌بینی بهتری است	در مقابل $DMS(\alpha = \lambda = 0.99)$ $DMS(\alpha = \lambda = 0.95)$
رد برابر بودن قدرت پیش‌بینی دو مدل	۷/۸۲ (۰/۰۰۰)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در مقابل $DMS(\alpha = \lambda = 0.99)$ $DMS(\alpha = \lambda = 0.9)$
رد برابر بودن قدرت پیش‌بینی دو مدل	۴/۲۴۵ (۰/۰۰۰)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMS(\alpha = \lambda = 0.95)$ مقابل $DMS(\alpha = \lambda = 0.9)$
عدم رد برابر بودن قدرت پیش‌بینی دو مدل	۱/۰۷۷ (۰/۲۸۱)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMA(\alpha = \lambda = 0.9)$ مقابل $DMS(\alpha = \lambda = 0.9)$
رد برابر بودن قدرت پیش‌بینی دو مدل	-۲/۹۲۵ (۰/۰۰۳)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMS(\alpha = \lambda = 0.9)$ مقابل $DMA(\alpha = 0.99, \lambda = 1)$
عدم رد برابر بودن قدرت پیش‌بینی دو مدل	-۱/۱۳۱ (۰/۲۵۷)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMS(\alpha = \lambda = 0.9)$ مقابل $DMA(\alpha = 0.95, \lambda = 1)$

²⁴ Diebold-Mariano



رد برابر بودن قدرت پیش‌بینی دو مدل	۳/۱۹۱ (۰/۰۰۱)	$DMA(\alpha = 0.95, \lambda = 1)$ دارای پیش‌بینی بهتری است	مقابل $DMA(\alpha = 0.99, \lambda = 1)$ $DMA(\alpha = 0.95, \lambda = 1)$
رد برابر بودن قدرت پیش‌بینی دو مدل	-۳/۴۷۶ (۰/۰۰۰)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMS(\alpha = \lambda = 0.9)$ مقابل $BMA(\alpha = \lambda = 1)$
رد برابر بودن قدرت پیش‌بینی دو مدل	-۶/۷۴ (۰/۰۰۰)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMS(\alpha = \lambda = 0.9)$ مقابل $TVP - AR(\lambda = 0.99)$
رد برابر بودن قدرت پیش‌بینی دو مدل	-۶/۹۳۹ (۰/۰۰۰)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در $DMS(\alpha = \lambda = 0.9)$ مقابل $TVP - AR(\lambda = 0.95)$
رد برابر بودن قدرت پیش‌بینی دو مدل	-۳/۱۷۵ (۰/۰۰۱)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در مقابل $DMS(\alpha = \lambda = 0.9)$ BVAR
رد برابر بودن قدرت پیش‌بینی دو مدل	-۳/۱۷۸ (۰/۰۰۱)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در مقابل $DMS(\alpha = \lambda = 0.9)$ $AR(1) - X(OLS)$
رد برابر بودن قدرت پیش‌بینی دو مدل	-۴/۷۵۶ (۰/۰۰۰)	$DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است	در مقابل $DMS(\alpha = \lambda = 0.9)$ $AR(1)(OLS)$
رد برابر بودن قدرت پیش‌بینی دو مدل	-۳/۲۹۴ (۰/۰۰۱)	$AR(1) - X(OLS)$ دارای پیش‌بینی بهتری است	در مقابل $AR(1) - X(OLS)$ $AR(1)(OLS)$

با توجه به نتایج بدست‌آمده از آزمون دیبولد-ماریانو در میان مدل‌های DMA مدل $DMA(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است و در میان مدل‌های DMS مدل $DMS(\alpha = \lambda = 0.9)$ دارای پیش‌بینی بهتری است. با مقایسه مدل $DMA(\alpha = \lambda = 0.9)$ و مدل $DMS(\alpha = \lambda = 0.9)$ ، مدل $DMS(\alpha = \lambda = 0.9)$ از پیش‌بینی بهتری برخوردار است. مقایسه مدل‌های $DMA(\alpha = 0.95, \lambda = 1)$ و $DMA(\alpha = 0.99, \lambda = 1)$ حاکی از آن است که مدل $DMA(\alpha = 0.95, \lambda = 1)$ دارای پیش‌بینی بهتری است و مقایسه آن با مدل $DMS(\alpha = \lambda = 0.9)$ نشان‌دهنده بهتر بودن عملکرد مدل $DMS(\alpha = \lambda = 0.9)$ می‌باشد. مقایسه مدل‌های TVP نشان داد که مدل $TVP - AR(\lambda = 0.99)$ از عملکرد بهتری برخوردار بوده و در مقایسه این مدل با $DMS(\alpha = \lambda = 0.9)$ مدل DMS دارای پیش‌بینی بهتری بوده است. در نهایت مقایسه مدل $DMS(\alpha = \lambda = 0.9)$ با مدل‌های $AR(1) - X(OLS)$ و $AR(1)(OLS)$ نیز نشان داد که مدل DMS از عملکرد بهتری برخوردار بوده است. بنابراین آزمون دیبولد-ماریانو نیز بر عملکرد بهتر مدل $DMS(\alpha = \lambda = 0.9)$ تاکید نموده است.

همان‌طور که مطرح‌شد از میان مدل‌های پیش‌بینی، تنها DMA و DMS، اجازه تغییر مدل‌های پیش‌بینی را در طول زمان می‌دهند. با توجه به تعداد بسیار زیاد مدل‌ها (۵۱۲ مدل) نمی‌توان نتایج را برای هر مدل ارائه نمود. اگرچه 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 گرفته‌شود، می‌توان تعداد بلوک‌های عاملی متوسط یا مورد انتظار

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

استفاده‌شده در DMA/DMS در زمان t را به صورت

در نظر گرفت. نمودار ۱ ارائه‌دهنده متوسط تعداد بلوک‌های عاملی 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 رعایت‌شده و همچنین، اصل صرفه‌جویی در داده‌های ابتدای دوره بیشتر مشهود است.



نمودار ۱. متوسط تعداد بلوک‌های عاملی پیش‌بینی‌کننده در هر تمرین پیش‌بینی
مأخذ: محاسبات تحقیق

Figure 1. Expected number of predictors in each forecasting exercise

Source: Research calculations

همان‌طور که مطرح‌شد در روش DMS، مدلی که دارای حداکثر احتمال است انتخاب می‌شود، به طوری‌که در این مطالعه در هر دوره زمانی از بین ۵۱۲ مدل ممکن، یک مدل به عنوان مدل بهینه برای پیش‌بینی متغیر مدنظر انتخاب می‌شود. بر این اساس، جدول ۵ بیانگر معادله‌هایی است که در بردارنده بیشترین سهم برای پیش‌بینی نرخ تورم به همراه دوره زمانی بکارگیری این معادلات و همین‌طور بلوک‌های تشکیل‌دهنده آنها می‌باشند.



بر اساس نتایج بدست‌آمده در افق پیش‌بینی یک فصل جلوتر، معادله‌ای که دربردارنده بلوک‌های پولی و ستاده است با سهم $13/3$ درصد در دوره‌های زمانی مندرج در جدول زیر، بیشترین میزان بکارگیری را در پیش‌بینی نرخ تورم داشته است. بعد از آن معادله‌ای که دارای بلوک‌های تقاضا، پولی، قیمتی، مالی و خارجی است با سهم $13/3$ درصد، سپس معادله‌ای که در بردارنده بلوک‌های تقاضا، پولی، قیمتی، خارجی و ستاده است با سهم $12/2$ درصد و در نهایت معادله‌ای که در بردارنده بلوک‌های تقاضا، نیروی کار، پولی، قیمتی، انرژی و خارجی است با سهم 10 درصد قرار دارند. این مدل‌ها به عنوان مدل‌هایی که در دوره زمانی مورد مطالعه بیشترین میزان استفاده را در تشکیل بهترین مدل (DMS) داشته‌اند (بالای 10 درصد)، مطرح می‌شوند. علاوه بر این، در این افق پیش‌بینی به ترتیب بلوک‌های پولی (۸۷ مرتبه)، قیمتی (۷۰ مرتبه)، خارجی (۴۹ مرتبه)، تقاضا (۴۶ مرتبه)، ستاده (۳۸ مرتبه)، انرژی (۳۷ مرتبه)، مالی (۳۶ مرتبه)، نیروی کار (۳۲ مرتبه) و دولت (۱۳ مرتبه) دارای بیشترین میزان استفاده در طول کل دوره مورد پیش‌بینی بوده‌اند.

در افق پیش‌بینی چهار فصل جلوتر، مدلی که حاوی بلوک‌های تقاضا، پولی، قیمتی، خارجی و ستاده است با $20/7$ درصد بیشترین میزان استفاده را در پیش‌بینی نرخ تورم داشته است. بعد از آن مدلی که حاوی بلوک‌های تقاضا، نیروی کار، پولی، قیمتی، انرژی و خارجی است با $13/8$ درصد قرار دارد. سپس مدلی که شامل بلوک‌های پولی و ستاده با $12/6$ درصد و همین طور مدلی که دربردارنده بلوک‌های تقاضا، پولی، قیمتی، مالی و خارجی هستند با $11/5$ درصد به عنوان مدل‌هایی که در دوره زمانی مورد مطالعه بیشترین میزان استفاده را در تشکیل بهترین مدل داشته‌اند (بالای 10 درصد)، مطرح می‌شوند.

علاوه بر این، در این افق پیش‌بینی بطور کلی بلوک پولی (۸۵ مرتبه)، قیمتی (۷۲ مرتبه)، تقاضا (۵۲ مرتبه)، خارجی (۴۹ مرتبه)، ستاده (۳۵ مرتبه)، انرژی (۳۰ مرتبه)، نیروی کار (۲۸ مرتبه)، مالی (۲۸ مرتبه) و دولت (۹ مرتبه) به ترتیب بیشترین میزان استفاده را در پیش‌بینی نرخ تورم در طول دوره مورد بررسی داشته‌اند.

در افق پیش‌بینی هشت فصل جلوتر، مدلی که حاوی بلوک‌های پولی، قیمتی، خارجی و ستاده است با $34/9$ درصد بیشترین میزان استفاده را در پیش‌بینی نرخ تورم داشته و بعد از آن مدلی که حاوی بلوک‌های پولی و ستاده است با $15/7$ درصد قرار دارد. این مدل‌ها به عنوان مدل‌هایی که در دوره زمانی مورد مطالعه بیشترین میزان استفاده را در تشکیل بهترین مدل داشته‌اند (بالای 10 درصد)، مطرح می‌شوند. بطور کلی در این افق

پیش‌بینی، بلوک‌های پولی (۸۱ مرتبه)، قیمتی (۶۱ مرتبه)، ستاده (۵۲ مرتبه)، خارجی (۴۸ مرتبه)، نیروی کار (۳۲ مرتبه)، انرژی (۲۸ مرتبه)، تقاضا (۱۷ مرتبه)، دولت (۷ مرتبه) و مالی (۶ مرتبه) بیشترین میزان استفاده را در طول دوره داشته‌اند.

جدول ۵. بلوک‌های پیش‌بینی‌کننده در بهترین مدل در دوره‌های زمانی و افق‌های پیش‌بینی مختلف
مأخذ: محاسبات تحقیق


Table 5. Predictors composing the best model on different forecast horizons

Source: Research calculations

سهم	بلوک‌های بکارگرفته شده در بهترین مدل	دوره زمانی	افق پیش‌بینی
۱۳/۳%	پولی، ستاده	۱۳۷۵q۲; ۱۳۷۵q۴; ۱۳۷۶q۱-۱۳۷۷q۱; ۱۳۷۷q۳-q۴; ۱۳۷۸q۳-۱۳۷۹q۱	h=۱
۱۳/۳%	تقاضا، پولی، قیمتی، مالی، خارجی	۱۳۸۰q۱-۱۳۸۱q۳; ۱۳۸۲q۱-q۳; ۱۳۸۸ q۲-۱۳۸۸q۳	
۱۲/۲%	تقاضا، پولی، قیمتی، خارجی، ستاده	۱۳۸۱q۴; ۱۳۸۳q۳-q۴; ۱۳۸۴q۲-۱۳۸۵q۲; ۱۳۸۶q۲-q۴	
۱۰%	تقاضا، نیروی کار، پولی، قیمتی، انرژی، خارجی	۱۳۸۷q۴; ۱۳۸۹q۲-q۳; ۱۳۹۰q۱; ۱۳۹۰ q۳-۱۳۹۱q۱; ۱۳۹۱q۴-۱۳۹۲q۱	
۲۰/۷%	تقاضا، پولی، قیمتی، خارجی، ستاده	۱۳۸۲q۱-۱۳۸۳q۱; ۱۳۸۳q۴; ۱۳۸۴q۲-۱۳۸۶q۴; ۱۳۸۷q۳	h=۴
۱۳٫۸%	تقاضا، نیروی کار، پولی، قیمتی، انرژی، خارجی	۱۳۸۸q۳; ۱۳۹۰q۲-۱۳۹۲q۴	
۱۲/۶%	پولی، ستاده	۱۳۷۶q۳-۱۳۷۷q۲; ۱۳۷۸q۲-۱۳۷۹q۴	
۱۱/۵%	تقاضا، پولی، قیمتی، مالی، خارجی	۱۳۸۰q۴-۱۳۸۱q۴; ۱۳۸۳q۲; ۱۳۸۷q۱-q۲; ۱۳۸۷q۴-۱۳۸۸q۱	
۳۴/۹%	پولی، قیمتی، خارجی، ستاده	۱۳۸۱q۱; ۱۳۸۱ q۴-۱۳۸۸q۳	h=۸
۱۵/۷%	پولی، ستاده	۱۳۷۷q۱; ۱۳۷۷ q۳-۱۳۷۸q۲; ۱۳۷۹q۱-۱۳۸۰q۴	


همان‌طور که مطرح شد، رافتری و همکاران (۲۰۰۷) 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 $b=1, \dots, B$ 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 که حاوی این بلوک عاملی باشد را برای پیش‌بینی استفاده می‌کند (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 بطور کامل کلیه مدل‌های حاوی این بلوک عاملی را در پیش‌بینی حذف می‌کند. خطوطی که بین صفر و یک قرار می‌گیرند دارای یک تفسیر میانی^{۲۵} می‌باشند. همان‌طور که در نمودار مشاهده می‌شود، بلوک‌هایی وجود دارند که به‌وضوح متغیرهای پیش‌بینی کننده مهمی هستند و نزدیک به یک هستند. این امر به‌خصوص در مورد بلوک‌های پولی و قیمتی مشهود می‌باشد.




نمودار ۲. احتمال کل از مدل‌های حاوی هر بلوک عاملی در افق پیش‌بینی یک فصل جلوتر ($h=1$)
 Figure ۲. Total probability of models which contain each factor block ($h=1$)

²⁵ intermediate interpretation



نمودار ۳. احتمال کل از مدل‌های حاوی هر بلوک عاملی در افق پیش‌بینی چهار فصل جلوتر ($h=4$)
Figure ۳. Total probability of models which contain each factor block ($h=4$)



نمودار ۴. احتمال کل از مدل‌های حاوی هر بلوک عاملی در افق پیش‌بینی هشت فصل جلوتر ($h=8$)
مأخذ: محاسبات تحقیق

Figure ۴. Total probability of models which contain each factor block ($h=8$)

Source: Research calculations

همان‌طور که نشان داده شد، در طول زمان شاهد تغییرات زیادی در متغیرهای پیش‌بینی‌کننده تورم هستیم که چنین تغییراتی را نمی‌توان با استفاده از روش‌های پیش‌بینی یا مدل‌های نظری مرسوم، مدلسازی نمود. به عنوان مثال، منحنی فیلیپس استاندارد مطرح می‌کند که نرخ بیکاری همیشه یک متغیر پیش‌بینی‌کننده خوب برای تورم است. اگر این بحث صحیح باشد، بلوک نیروی کار همیشه یک پیش‌بینی‌کننده خوب برای تورم است و در

نتیجه بایستی احتمال کل مدلهایی که حاوی بلوک نیروی کار هستند در نمودارهای فوق نزدیک به یک بود. در حالیکه نتایج این مقاله چنین امری را نشان نمی‌دهد. نتایج نشان می‌دهد که بلوک پولی، بلوک مهمی برای پیش‌بینی نرخ تورم ایران بوده است. از منظر ادبیات نظری این نتیجه با مدل‌های نیوکینزین‌ها مطابقت دارد، جایی که نرخ تورم در وضعیت پایدار^{۲۶} با استفاده از نرخ رشد پول تعیین می‌شود. هنگام پیش‌بینی تورم تقریباً تمام بلوک‌های عاملی نقش قابل توجهی دارند و تنها بلوک دولت است که کم‌ترین اثرگذاری را داشته است.

۶- نتیجه‌گیری

نرخ تورم بالا در ایران یکی از مهم‌ترین مشکلات اقتصاد ایران بوده که موجب عدم ثبات و نااطمینانی در فضای کلان اقتصادی شده است. بنابراین، مطالعه و بررسی انواع مدل‌های پیش‌بینی به منظور دستیابی به مدلی برتر نسبت به سایر رویکردها از اهمیت زیادی در ادبیات تجربی اقتصاد ایران برخوردار است. این مقاله پیش‌بینی نرخ تورم شاخص قیمت مصرف‌کننده در ایران را با استفاده از داده‌های فصلی طی دوره ۱۳۶۹ تا ۱۳۹۶ بر اساس مجموعه‌ای متشکل از متغیرهای پیش‌بینی‌کننده بسیاری با روش‌های گزینشی‌نمودن (DMS) و متوسط‌گیری الگوی پویا (DMA) مورد بررسی قرار داد. 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 پیش‌بینی‌کننده مورد استفاده در پیش‌بینی و مدل‌ها در طول زمان تغییر کنند.

نتایج نشان داد که پیش‌بینی مدل‌های گزینشی‌نمودن (DMS) و متوسط‌گیری الگوی پویا (DMA) نسبت به سایر روش‌های پیش‌بینی سنتی دارای عملکرد کارایی برای نرخ تورم ایران بوده‌اند. علاوه بر این استفاده از بلوک عاملی نشان داد که عوامل پیش‌بینی‌کننده در طول زمان دچار تغییر می‌شوند. یافته‌ها حاکی از آن است که در تمامی افق‌های پیش‌بینی، بلوک‌های پولی و قیمتی دارای بیشترین تعداد در استفاده از مدل بهینه در طول زمان بوده و کمترین تعداد نیز به بلوک دولت اختصاص داشته است. در مجموع می‌توان گفت مدل DMA میانگین‌گیری از تعداد زیادی مدل است و تنها از یک بلوک عاملی استفاده نمی‌کند

²⁶ Steady-state

(همچنین بلوک عاملی بی‌ربطی نیز وجود ندارد) و این امر مهم‌ترین ویژگی استفاده از DMA/DMS است.

Acknowledgments: Acknowledgments may be made to individuals or institutions that have made an important contribution.

Conflict of Interest: The authors declare no conflict of interest.

Funding: The authors received no financial support for the research, authorship, and publication of this article.

Reference

- Ang, A., Bekaert, G., & Wei, M. (2007). Do Macro Variables, Asset Markets, or Surveys Forecast Inflation Better? *Journal of Monetary Economics*, 54, 1163–1212.
- Atkeson, A., & Ohanian, L. E. (2001). Are Phillips curves useful for forecasting inflation? *Federal Reserve Bank of Minneapolis Quarterly Review*, 25(1), 2–11.
- Avramov, D. (2002). Stock Return Predictability and Model Uncertainty, *Journal of Financial Economics*, 64, 423–58.
- Aye, G., Gupta, R., Hammoudeh, SH., & Kim, W.J. (2015). Forecasting the Price of Gold Using Dynamic Model Averaging, University of Pretoria, *Department of Economics Working Paper Series*.
- Bayani, O. & Mohammadi, T. (2019). Factors Affecting Financial Crises: The Bayesian Model Averaging, *Quarterly Journal of Quantitative Economics (JQE)*, 16(2), 145-180. Available at: https://jqe.scu.ac.ir/article_14275.html?lang=en [In Persian]
- Balcilar, R., Gupta, R., Eyden, R.V., 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.
- Barsoum, F., & Stankiewicz, S. (2015). Forecasting GDP growth using mixed-frequency models with switching regimes. *International Journal of Forecasting*, 31(1), 33-50.

- 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.
- Bork, L., & Møller, S. V. (2015). Forecasting house prices in the 50 states using Dynamic Model Averaging and Dynamic Model Selection. *International Journal of Forecasting*, 31(1), 63-78.
- Brave, S., & Fisher, J. (2004). In search of a robust inflation forecast. *Federal Reserve Bank of Chicago, Economic Perspectives*, 28(4), 11–31.
- Buncic, D. & G-M. Frey. (2012). Forecasting commodity currencies with dynamic Bayesian Models. Working paper, Institute of Mathematics and Statistics, University of St Gallen, Switzerland.
- 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.
- Canova, F. (2007). G-7 inflation forecasts: random walk, Phillips Curve or what else? *Macroeconomic Dynamics*, 11, 1–30.
- Cechetti, SG. (1995). Inflation indicators and inflation policy. Working paper 5161, NBER.
- Cechetti, S., Chu, R., Steindel C. (2000). The unreliability of inflation indicators. *Current Issues in Economics and Finance*, 6(4), 1–6.
- 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.
- Cremers, K. (2002). Stock Return Predictability: A Bayesian Model Selection Perspective. *Review of Financial Studies*, 15, 1223–1249.

- De Bruyn, R., Gupta, R., & van Eyden, R. (2013). Forecasting the rand-dollar and rand-pound exchange rates using dynamic model averaging. Working paper 2013-07, University of Pretoria.
- Dupasquier, C., & Ricketts, N. (1998). Non-linearities in the output-inflation relationship: some empirical results for Canada. Working paper 98-14, Bank of Canada.
- Elliott, G., & Timmermann, A. (Eds.). (2013). *Handbook of economic forecasting*. 2, Elsevier.
- Ferreira, D., & Palma, A. (2015). Forecasting Inflation with the Phillips Curve: A Dynamic Model Averaging Approach for Brazil. *Revista Brasileira de Economia*, 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.
- Fisher, J., Liu, C., & Zhou, R. (2002). When can we forecast inflation? *Economic Perspectives*, 26(1), 32-44.
- Grassi, S., & De Magistris, P.S. (2015). It's all about volatility (of volatility): Evidence from a two-factor stochastic volatility model. *Journal of Empirical Finance*, 60, 62-78.
- Groen, J., Paap, R., & Ravazzolo, F. (2010). Real-time Inflation Forecasting in a Changing World, Federal Reserve Bank of New York Staff Report Number 388.
- Gupta, R., Hammoudeh, S.H., 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.
- Holden, K., Peel, D.A., & Thompson, J.L. (1999). *Economic forecasting: an introduction*, Cambridge University Press.
- Kim C-J., & Nelson CR. (1998). *State-Space Models with Regime-Switching: Classical and Gibbs-Sampling Approaches with Applications*. MIT Press: Cambridge, MA.

- Koop, G., & Potter, S. (2004). Forecasting in dynamic factor models using Bayesian model averaging. *The Econometrics Journal*, 7, 550–565.
- Koop, G., & Korobilis, D. (2011). UK macroeconomic forecasting with many predictors: Which models forecast best and when do they do so? *Economic Modelling*, 28, 2307–2318.
- Koop, G., & Korobilis, D. (2012). Forecasting Inflation Using Dynamic Model Averaging. *International Economic Review*, 53(3), 867-886.
- Koop, G., & Tole, L. (2012). Forecasting the European carbon market. *Journal of the Royal Statistical Society, Series A*, 176(3), 723–741.
- Lansing, KJ. (2002). Can the Phillips curve help forecast inflation? *Economic Letter No. 2002-29*, Federal Reserve Bank of San Francisco.
- Naser, H. & Alaali, F. (2018). Can Oil Prices Help Predict US Stock Market Returns: An Evidence Using a DMA Approach? *Empirical Economics*, 55(4), 1757-1777.
- Nicoletti, G., & Passaro, R. (2012). Sometimes it helps: the evolving predictive power of spreads on GDP dynamics. ECB working paper series 1447.
- Pesaran, M. H., & Timmermann, A. (2000). A Recursive Modelling Approach to Predicting UK Stock Returns. *The Economic Journal*, 110, 159–91.
- Primiceri, G. (2005). Time Varying Structural Autoregressions and Monetary Policy. *Review of Economic Studies*, 72, 821-852.
- Raftery, A., Karny, M., Andrysek, J., & Ettler, 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., Karny, M., & Ettler, P. (2010). Online prediction under model uncertainty via dynamic model averaging: application to a cold rolling mill. *Technometrics*, 52(1), 52–66.
- Rahimpoor, A., Yarmohamadi, M., Chinipardaz, R. & Shadrokh, A. (2020). Modeling golden and dollar data by robust simulation-based estimation. *Quarterly Journal of Quantitative Economics (JQE)*, 17(1), 35-60. https://jqe.scu.ac.ir/article_14619.html?lang=en [In Persian].

-
- Stock, J.H. & Watson, M.W. (1996). Evidence on Structural Instability in Macroeconomic Time Series Relations. *Journal of Business and Economic Statistics*, 14, 11-30.
- Stock, J.H. & Watson, M.W. (1999). Forecasting Inflation. *Journal of Monetary Economics*, 44, 293-335.
- Stock, J.H. & Watson, M.W. (2003). Forecasting output and inflation: the role of asset prices. *Journal of Economic Literature*, 41(3), 788-829.
- Stock, J.H. & Watson, M.W. (2007). Why has US inflation become harder to forecast? *Journal of Money, Credit, and Banking* 39(Suppl. 1), 3-33.
- Stock, J.H. & Watson, MW. (2008). Phillips Curve Inflation Forecasts, NBER Working Paper No. 14322.
- Tinbergen, J. (1939). *Business cycles in the United States of America: 1919-1932*. League of Nations.