

بررسی عملکرد رگرسیون داده‌های ترکیبی با تواتر متفاوت

در پیش‌بینی تورم فصلی ایران^۱

سید مهدی برکچیان*

محمد حسین رضائی**

تاریخ پذیرش
۱۳۹۵/۱/۲۱

تاریخ دریافت
۱۳۹۴/۸/۸

چکیده

این مطالعه به بررسی قدرت پیش‌بینی مدل‌های خودرگرسیون با داده‌های با تواتر متفاوت در پیش‌بینی نرخ تورم فصلی برای اقتصاد ایران می‌پردازد. به این منظور، دقت پیش‌بینی مدل‌های خودرگرسیونی که از وقفه‌های ماهانه نرخ تورم استفاده می‌کنند در برابر مدل پایه‌ای که از اطلاعات فصلی تغذیه می‌کند، مقایسه شده است. نتایج نشان می‌دهد که استفاده از مشاهدات ماهانه نرخ تورم در پیش‌بینی تورم فصلی غالباً منجر به بهبود دقت نتایج در پیش‌بینی تورم شده است. این بهبود بطور ویژه خود را در پیش‌بینی یک گام به جلو نشان می‌دهد. در میان الگوهای مورد بررسی، رگرسیون‌های میداس عمدتاً در افق‌های پیش‌بینی یک گام، سه گام و چهار گام به جلو نسبت به مدل پایه از دقت بالاتری برخوردار بوده‌اند. مدل وزن‌دهی گام به گام که دارای تعداد پارامترهای زیادی است، نسبت به مدل رگرسیون میداس که دارای ویژگی‌های غیرخطی و تعداد پارامتر محدودتری است، پیش‌بینی‌های نسبتاً دقیق‌تری ارائه کرده است.

کلید واژه‌ها: پیش‌بینی تورم، رگرسیون میداس، مدل‌های خودرگرسیون.

طبقه‌بندی JEL: C22, C51, C53, E31.

^۱ این مطالعه با حمایت پژوهشکده پولی و بانکی بانک مرکزی انجام شده است. ضمناً از نظرات دکتر سیدعلی مدنی‌زاده، مدیر گروه مدلسازی پژوهشکده پولی و بانکی بانک مرکزی، در انجام این پژوهش قدردانی می‌گردد.
* استادیار گروه اقتصاد دانشکده مدیریت و اقتصاد دانشگاه صنعتی شریف، barakchian@sharif.edu
** کارشناس ارشد علوم اقتصادی دانشکده مدیریت و اقتصاد دانشگاه صنعتی شریف (نویسنده مسئول)، rezaei.mh66@gmail.com

۱. مقدمه

پیشرفت تکنولوژی در دهه‌های اخیر، امکان دسترسی به اطلاعات مالی و اقتصادی را با تواتر بالا برای دوره زمانی کوتاه‌تر فراهم آورده است. متغیرهای مالی معمولاً با تواتر روزانه یا بالاتر گزارش می‌شوند. اما ماهیت متغیرهای اقتصاد کلان به گونه‌ای است که این متغیرها را نمی‌توان با تواتر بالا مشاهده کرد و عمدتاً با تواتر ماهانه یا پایین‌تر گزارش می‌شوند. سؤالی که در اینجا مطرح می‌شود آن است که بهترین روش استفاده از اطلاعات با تواتر مختلف کدام است؟

در رویکرد مرسوم برای مدلسازی متغیرهای با تواتر متفاوت، می‌بایست ابتدا تمامی متغیرهای مدل هم‌تواتر شده سپس وارد مدل شوند. برای یکسان‌سازی تواتر متغیرها دو راهکار وجود دارد: ۱- یکسان‌سازی تواتر متغیرها به سمت متغیر با بالاترین تواتر، ۲- یکسان‌سازی تواتر متغیرها به سمت متغیر با پایین‌ترین تواتر. در ادبیات سری‌های زمانی، روش اول موسوم به «همفزونی زمانی»^۱ است و روش دوم، «جداسازی زمانی»^۲ نام‌گذاری شده است. همفزونی زمانی عبارت است از کاهش تواتر یک متغیر به کمک میانگین‌گیری یا مجموع‌یابی آن متغیر در طول زمان. با این کار مدل در پایین‌ترین تواتر برآورد می‌شود، لذا با همفزونی زمانی، مجموعه‌ی اطلاعاتی در دسترس کوچک می‌شود. اساساً سری همفزون یافته در مقایسه با سری ابتدایی آن از روندی هموارتر و ساده‌تر برخوردار است. این اثر در مورد تبدیلات بزرگتر تواتر (مثلاً تبدیل ماه به سال در مقایسه با تبدیل فصل به سال) شدیدتر رخ می‌دهد. به همین خاطر، در تحقیقات اقتصادی که حجم نمونه کوچک است، استفاده از روش همفزونی زمانی توصیه نمی‌شود. اما در روش جداسازی، برخلاف روش همفزونی، مدل در بالاترین تواتر تخمین زده می‌شود. به این منظور فرض می‌شود که سری زمانی در بستر زمانی با تواتر بالا تولید

^۱ Temporal Aggregation

^۲ Temporal Disaggregation

می‌شود، درحالی‌که بطور سیستماتیک، تنها در برخی مقاطع زمانی قابل مشاهده است. جداسازی بدین معنی است که مقادیر غیر قابل مشاهده (یا به اصطلاح مشاهدات مفقوده) را به روشی بازیابی کنیم. مزیت روش جداسازی نسبت به روش همفزونی در این است که در این روش اطلاعات مربوط به متغیر با تواتر بالا از بین نمی‌رود. معایب و مزایای هرکدام از دو روش مذکور در ادبیات به تفصیل بررسی شده است (برای مطالعه‌ی بیشتر به مقاله سیلوسترینی و ورداس^۱ (۲۰۰۸) در مورد ویژگی‌های روش همفزونی زمانی و مقاله نجمان و پالم^۲ (۱۹۹۰) در مورد مزیت روش جداسازی زمانی مراجعه شود).

«مدل‌های داده‌های با تواتر متفاوت»^۳ اصطلاحاً به مدل‌هایی گفته می‌شود که متغیرها در آنها همزمان با تواتر متفاوت وارد می‌شوند. این مدل‌ها با توجه به دو راهکار مطرح شده در بالا به دو گروه تقسیم می‌شوند؛ گروه اول مدل‌هایی که از همفزونی زمانی نشأت می‌گیرند و گروه دوم مدل‌هایی که مبتنی بر جداسازی زمانی ساخته می‌شوند. مدل‌های رگرسیون میداس^۴، به عنوان نمونه تکامل‌یافته روش همفزونی زمانی، در گروه اول و مدل‌های حالت-فضا^۵ در گروه دوم قرار می‌گیرند. در یک مدل حالت-فضا می‌بایست دینامیک تک‌تک متغیرهای با تواتر بالا مدلسازی شده و به کمک فیلتر کالمن^۶ به تخمین پارامترهای مدل و مشاهدات مفقوده پرداخت. بنابراین هرچه تعداد متغیرهای مدل افزایش یابد و یا اختلاف تواتر متغیرهای مدل زیاد شود، بر پیچیدگی مدل افزوده خواهد شد. این در حالی است که مدل رگرسیون میداس نسبت به مدل حالت-فضا از سادگی و اختصار بیشتری برخوردار است. مزیت عمده رگرسیون

^۱ Silvestrini and Veredas

^۲ Nijman and Palm

^۳ Mixed-Frequency Models

^۴ Mixed Data Sampling (MIDAS)

^۵ State-space

^۶ Kalman Filter

میداس نسبت به مدل‌های حالت-فضا در تعداد کم پارامترهای برآوردی و فرم خلاصه‌تر آن است. بای و همکاران^۱ (۲۰۱۱) نشان دادند که اگرچه دقت مدل فیلتر کالمن در مواردی بالاتر از رگرسیون میداس است، در حالت کلی، رگرسیون میداس نتایجی شبیه به مدل فیلتر کالمن دارد. علاوه بر این مدل میداس پیچیدگی‌های محاسباتی مدل فیلتر کالمن را نداشته و از اختصار در برآورد پارامترها برخوردار است. اندرو و همکاران^۲ (۲۰۱۲) به این نتیجه رسیدند که دقت پیش‌بینی مدل‌ها به کمک رگرسیون میداس افزایش می‌یابد. در مورد پیش‌بینی متغیرهای اقتصاد کلان از جمله تورم، آرمستو و همکاران^۳ (۲۰۱۰) در مطالعه‌ای برای فدرال رزرو سنت لوئیس نشان دادند که مدل رگرسیون میداس دقت پیش‌بینی تورم را خصوصاً برای پیش‌بینی‌های زمان جاری^۴ می‌تواند بالا ببرد.

در تحقیق داخلی انجام شده، نوفرستی و بیات (۱۳۹۳) به پیش‌بینی رشد اقتصادی ایران (رشد تولید ناخالص داخلی) با تواتر فصلی به کمک متغیرهای فصلی و ماهانه اقتصادی توسط رگرسیون میداس پرداخته‌اند. مقایسه نتایج پیش‌بینی‌های بدست‌آمده از این مقاله با مقادیر محقق‌شده نشان از عملکرد نسبتاً دقیق رگرسیون میداس دارد. با این حال، بسته به نوع متغیر هدف و ریسک سیستماتیک متناسب با هر اقتصاد، عملکرد رگرسیون میداس ممکن است متفاوت باشد. برکچیان و رضائی (۱۳۹۳) در تحقیقی دیگر به ارزیابی رگرسیون‌های میداس در پیش‌بینی ارزش در معرض ریسک چنددوره‌ای برای پورتفوی منتخب سرمایه‌گذاری شده در بورس اوراق بهادار تهران پرداخته‌اند. نتایج این مقاله نشان می‌دهد که استفاده از رگرسیون میداس دقت پیش‌بینی‌ها را نسبت به مدل‌های با تواتر ثابت بطور معنادار افزایش نداده است.

^۱ Bai, Ghysels and Wright

^۲ Andreou, Ghysels and Kourtellos

^۳ Armesto, Engemann and Owyang

^۴ Real Time Forecasts

با در نظر گرفتن این موضوع که یکی از مهمترین اهداف بانک مرکزی، کنترل نرخ تورم در اقتصاد است، پیش‌بینی هر چه دقیق‌تر نرخ تورم برای سیاست‌گذار پولی از اهمیت بالایی برخوردار است. بدین منظور تاکنون، روش‌های متفاوتی برای پیش‌بینی تورم مورد بررسی قرار گرفته و پیشنهاد شده است که هر کدام به نوعی سعی در افزایش دقت پیش‌بینی نرخ تورم دارند. از جمله روش‌های مورد بررسی در ادبیات پیش‌بینی تورم در ایران می‌توان به استفاده از روش شبکه‌های عصبی مصنوعی (مشیری (۱۳۸۰)، زراء نژاد و حمید (۱۳۸۸) و شهیکی‌تاش و همکاران (۱۳۹۲))، روش مدل‌های خودرگرسیون برداری (حیدری (۱۳۹۰))، روش معادلات دیفرانسیل تصادفی (بهرامی و همکاران (۱۳۹۰))، روش تفکیک اجزای شاخص و مدل‌های عاملی (بیات و برکچیان (۱۳۹۳))، روش ترکیب پیش‌بینی‌ها (عطریانفر و برکچیان (۱۳۹۲)) و روش منحنی فیلیپس (طیب‌نیا و همکاران (۱۳۹۲) و برکچیان و همکاران (۱۳۹۳)) اشاره کرد. علیرغم غنای مطالعات صورت گرفته در این زمینه تاکنون عملکرد مدل‌های داده‌های با تواتر متفاوت به منظور پیش‌بینی تورم ایران (که بصورت فصلی هر ماه از سوی بانک مرکزی ایران گزارش می‌شود) مورد بررسی قرار نگرفته است، در این مقاله از روش رگرسیون داده‌های با تواتر متفاوت (شامل مدل وزن‌دهی گام به گام و مدل رگرسیون میداس) به عنوان روشی نوین برای پیش‌بینی تورم فصلی استفاده شده است. در این رویکرد برای پیش‌بینی تورم فصلی از متغیرهای توضیح‌دهنده با تواتر بالاتر از فصل (در این مقاله تواتر ماهانه) استفاده می‌شود.

نتایج بدست آمده در این مقاله بازگو کننده افزایش دقت پیش‌بینی‌های فصلی

تورم (خصوصاً پیش‌بینی‌های یک گام به جلو) به هنگام استفاده از اطلاعات با تواتر بالاتر است. نکته دیگر اینکه، مدل رگرسیون میداس در برابر روش ساده ترکیب تواتر عملکرد بهتری از خود نشان نداده است. البته بطور کلی، تفاوت پیش‌بینی‌های بدست آمده از مدل‌های مختلف اندک بوده و به لحاظ آماری معنادار نیست. در این مقاله، دقت

پیش‌بینی دو روش رگرسیون میداس و وزن‌دهی گام به گام، به عنوان نماینده روش‌های با تواتر متفاوت، در برابر روش مرسوم پیش‌بینی که در یک تواتر یکسان برآورد صورت می‌گیرد (بعنوان مدل پایه)، مقایسه شده است.

ادامه مقاله بدین شرح است؛ در بخش ۲، مدل‌های با تواتر متفاوت معرفی و توضیح داده شده‌اند. در بخش ۳، متدلوژی و داده‌های مورد استفاده در مقاله بیان شده‌اند. در بخش ۴، نتایج برآورد مدل‌ها ارائه شده و مقایسه بین نتایج صورت‌گرفته و در نهایت در بخش ۵ مقاله نتیجه‌گیری انجام شده است.

۲. مبانی نظری

در رگرسیون میداس^۱، معرفی شده از جانب گایسلز و همکاران^۲ (۲۰۰۵ و ۲۰۰۶)، متغیرهای مستقل نسبت به متغیر وابسته از تواتر بالاتری در واحد زمان برخوردارند. این روش می‌تواند از اطلاعات با تواتر بالا در سمت متغیرهای مستقل استفاده کرده و به پیش‌بینی متغیر وابسته در تواتر دلخواه پرداخت. **بطور کلی، هرگاه هدف پیش‌بینی متغیری در تواتر پایین‌تر از تواتر انتشار آن باشد، استفاده از رگرسیون میداس مناسب خواهد بود.** این روش نمونه‌ی تکامل‌یافته‌ی مدل‌های با توزیع وقفه^۳ بوده که از انعطاف‌پذیری بالایی در تخمین پارامترها و برازش الگوی مناسب برخوردار است. رگرسیون میداس برای یک حالت دو متغیره و پیش‌بینی یک گام جلوتر^۴ بصورت زیر تصریح می‌شود:

$$y_{t+1} = \beta_0 + \beta_1 B(L^{1/m}; \theta) x_t^{(m)} + \epsilon_t \quad (1)$$

^۱ Mi(xed) Da(ta) S(ampling)

^۲ Ghysels, Santa-clara and Valkanov

^۳ Distributed Lag Models

^۴ One step ahead

در رابطه‌ی (۱)، y_{t+1} متغیر وابسته (در توأتر پایین)، $x_t^{(m)}$ متغیر مستقل (در یک توأتر بالاتر) و $B(L^{1/m}; \theta) = \sum_{j=0}^{j^{max}} B(j; \theta)L^{j/m}$ نشان‌دهنده‌ی تابع وزن‌دهی به وقفه‌های متغیر مستقل است و $L^{j/m}x_t^{(m)} = x_{t-j/m}^{(m)}$ نماینده‌ی عملگر وقفه‌ی کسری است، t اندیس زمان مرجع (توأتر متغیر وابسته) بوده و m ترکیب توأتر را نشان می‌دهد.^۱ ϵ_t در مدل (۱) جزء خطا با ویژگی‌های «توفه سفید»^۲ است که در توأتر متغیر وابسته محاسبه می‌شود. برای مثال، رگرسیون میداس با مشخصات $m = 3$ و $j^{max} = 6$ چنین تصریح می‌گردد:

$$y_{t+1} = \beta_0 + \beta_1 B(L^{1/3}; \theta)x_t^{(3)} + \epsilon_t \quad (۲)$$

در این حالت، $B(L^{1/3}; \theta) = \sum_{j=0}^6 B(j; \theta)L^{j/3}$ و $L^{j/3}x_t^{(3)} = x_{t-j/3}^{(3)}$ است. چنانچه اجزای تابع وزن‌دهی درون رگرسیون (۲) قرار گیرد، رابطه‌ی (۳) بدست می‌آید:^۳

$$y_{t+1} = \beta_0 + \beta_1 [B(0; \theta)x_t^{(3)} + B(1; \theta)x_{t-1/3}^{(3)} + B(2; \theta)x_{t-2/3}^{(3)} + B(3; \theta)x_{t-1}^{(3)} + \dots + B(6; \theta)x_{t-2}^{(3)}] + \epsilon_t \quad (۳)$$

در پیش‌بینی h دوره‌ی بعد متغیر وابسته، متغیرهای مستقل نسبت به متغیر وابسته، h دوره فاصله‌ی زمانی دارند.

$$y_{t+h} = \beta_0 + \beta_1 B(L^{1/m}; \theta)x_t^{(m)} + \epsilon_t \quad (۴)$$

نوآوری و اهمیت رگرسیون میداس در تابع وزن‌دهی $B(j; \theta)$ نهفته است. چرا که در یک ساختار صرفه‌جویانه ضرایب وقفه‌های مدل را شناسایی و برآزش می‌کند. برای

^۱ در نمادگذاری مدل‌های با فرکانس مختلط از دو عملگر وقفه استفاده می‌شود. اولین عملگر، t (اندیس زمان مرجع)، برای مثال نشان‌دهنده یک فصل، و دومین عملگر، j/m (اندیس زمان کسری)، برای مثال نشان‌دهنده یک ماه است.

^۲ White Noise

^۳ چنانچه y_{t+1} اولین فصل سال ۱۳۹۳ (ابتدای فروردین تا انتهای خرداد) باشد، x_t نشان‌دهنده انتهای اسفند ۱۳۹۲ (نماینده‌ی اسفند ماه)، $x_{t-1/3}$ نشان‌دهنده انتهای بهمن ۱۳۹۲ (نماینده‌ی بهمن ماه) و به همین ترتیب برای دیگر ماه‌ها تا شهریور ۱۳۹۲ را خواهیم داشت.

درک بهتر ابتدا دو راهکار ساده‌تر برای برآورد پارامترهای مدل در نظر گرفته شده، سپس تابع وزن‌دهی در مدل میداس بررسی می‌شود.

در برخورد با متغیرهای با تواتر متفاوت، در اولین رویکرد می‌توان وقفه‌های با تواتر بالای متغیر مستقل را در هر بازه‌ی زمانی مرجع میانگین‌گیری کرد. این روش «هم‌فزونی زمانی» نام دارد که به وقفه‌های با تواتر بالا وزن یکسان نسبت می‌دهد. مدل در این حالت به صورت زیر نمایش داده می‌شود:

$$y_{t+1} = \beta_0 + \beta_1 X_t + \epsilon_t, \quad X_t = \frac{1}{m} \sum_{j=0}^{m-1} x_{t-j/m} \quad (5)$$

اندرو و همکاران^۱ (۲۰۱۰) نشان دادند که هم‌فزونی زمانی می‌تواند منجر به خطای تصریح^۲ و ایجاد ناسازگاری^۳ در مدل بشود. اما در دومین رویکرد، می‌توان به هر وقفه درون مدل، یک وزن ویژه اختصاص داد. بصورتی که در رابطه (۶) مشاهده می‌شود.

$$y_{t+1} = \beta_0 + \beta_{1j} \sum_{j=0}^{m-1} x_{t-j/m} + \epsilon_t \quad (6)$$

این روش که «وزن‌دهی گام به گام»^۴ نام دارد نسبت به هم‌فزونی زمانی دقیق‌تر عمل می‌کند، چرا که به وقفه‌ها وزن یکسان نسبت نمی‌دهد. البته که دقیق‌ترین نوع برآورد به لحاظ نظری همین روش است؛ اما مسئله این است که وقتی ترکیب تواتر (m) بزرگ می‌شود، تعداد پارامترهای برآوردی در مدل زیاد می‌شود. برای مثال هرگاه $m = 66$ باشد (یعنی ترکیب داده‌های ماهیانه و روزانه مد نظر باشد)، با احتساب عرض از مبدأ می‌بایست ۶۷ پارامتر برآورد شود. تعداد زیاد پارامترهای مدل منجر به ناپایداری نتایج پیش‌بینی‌های مدل بیرون از نمونه می‌شود. لذا کم بودن تعداد پارامترهای مدل، علاوه بر سادگی به پایداری نتایج آن نیز کمک می‌کند.^۵ روش میداس در مقایسه با دو روش نامبرده از یک چندجمله‌ای وزنی $(B(L^{1/m}; \theta))$ برای وزن‌دهی وقفه‌های با تواتر

^۱ Andreou, Ghysels and Kourtellos

^۲ Misspecification

^۳ Inconsistency

^۴ Step Weighting

^۵ این مسئله در ادبیات اقتصادسنجی «تکثر پارامترها» (Proliferation of Parameters) نامیده می‌شود.

بالا استفاده می‌کند، این چندجمله‌ای می‌بایست شرایط زیر را برقرار سازد.

۱. وزن‌های اختصاص یافته به وقفه‌ها مثبت باشند؛ این شرط خصوصاً برای برخی کاربردها (مانند پیش‌بینی واریانس) ضروری است.
۲. جمع وزن‌ها برابر با یک شود؛ این قید برای شناسایی عرض از مبدأ (β_1) در رابطه‌ی (۱) در نظر گرفته می‌شود.
۳. فرم تابع وزندهی تحت تأثیر تعداد پارامترهای کمی (θ) بوده و در عین حال از انعطاف‌پذیری بالایی برخوردار باشد.

متناسب با شرایط ذکرشده، برای تابع وزندهی توابع چندجمله‌ای (محدود یا نامحدود) متفاوتی ارائه شده است. گایسلز و همکاران (۲۰۰۴) توابع «نمایی آلمن»^۱ و «بتا»^۲ را پیشنهاد کردند و گایسلز و همکاران^۳ (۲۰۰۶) به بررسی ویژگی‌های دو تابع بتا و نمایی آلمن پرداختند. البته توابع وزندهی در رگرسیون میداس به این دو تابع ختم نمی‌شود. در واقع، رگرسیون میداس در انتخاب فیلتر وزندهی بسته به نوع داده‌ها و موضوع مورد بررسی از انعطاف بالایی برخوردار است. (برای مطالعه بیشتر به کتاب «اقتصاد سنجی کاربردی سری‌های زمانی: الگوی داده‌های ترکیبی با تواتر متفاوت» نوشته محبوبه بیات و محمد نوفرستی مراجعه شود).

۳. متدولوژی و داده‌ها

هدف از انجام این مطالعه پاسخ دادن به این سؤال است که آیا استفاده از شاخص قیمت مصرف‌کننده با تواتر ماهانه می‌تواند دقت پیش‌بینی تورم فصلی را افزایش دهد یا خیر؟ به این منظور، دقت پیش‌بینی مدل‌های با تواتر متفاوت با مدل پایه^۴ که در تواتر فصلی تخمین زده می‌شود مقایسه می‌شود. به عبارت دیگر، در مدل‌های با تواتر متفاوت،

^۱ Exponential Almon Lag

^۲ Beta Function

^۳ Ghysels, Sinko and Valkanov

^۴ Benchmark

وقفه‌های مدل با تواتر ماهانه وارد مدل می‌شوند، اما در مدل پایه، وقفه‌های مدل با تواتر فصلی در نظر گرفته می‌شوند.

در مدل‌های با تواتر متفاوت، دو روش رگرسیون میداس، مدل (۴)، و وزن‌دهی گام به گام، مدل (۶)، بررسی می‌شوند. در هر دوی این روش‌ها، وقفه‌های تورم بصورت ماهانه وارد مدل می‌شوند، با این تفاوت که در رگرسیون میداس، ضرایب وقفه‌ها با استفاده از یک تابع وزن‌دهی مشخص می‌شوند، در حالیکه در روش وزن‌دهی گام به گام، برای تک‌تک وقفه‌ها، بصورت جداگانه و به روش حداقل مربعات، ضریب برآورد می‌گردد. در برآورد رگرسیون میداس، از توابع وزن بتا، آلمن‌نمایی، با دو پارامتر برآوردی، و تابع وزن نمایی^۱ استفاده شده است. در زیر، فرم توابع وزن‌دهی که در این مقاله مورد استفاده قرار گرفته‌اند، نشان داده شده است.

تابع نمایی آلمن:

$$B(j; \theta) = \frac{\exp(\theta_1 j + \theta_2 j^2 + \dots + \theta_p j^p)}{\sum_{j=1}^{j^{max}} \exp(\theta_1 j + \theta_2 j^2 + \dots + \theta_p j^p)} \quad (7)$$

هرچه p در تابع وزن (۷) کوچکتر باشد، تعداد پارامترهای مدل کمتر شده و از طرف دیگر از انعطاف‌پذیری تابع وزن کاسته می‌شود. در مقاله حاضر، p برابر با ۲ لحاظ شده است.

تابع بتا:

$$B(j; \theta) = \frac{f\left(\frac{j}{j^{max}}, \theta_1, \theta_2\right)}{\sum_{j=1}^{j^{max}} f\left(\frac{j}{j^{max}}, \theta_1, \theta_2\right)} \quad (8)$$

$$f(x, a, b) = \frac{x^{a-1}(1-x)^{b-1}\Gamma(a+b)}{\Gamma(a)\Gamma(b)}, \quad \Gamma(a) = \int_0^\infty e^{-x} x^{a-1} dx$$

^۱تابع وزن نمایی توسط مؤلفین این مقاله انتخاب شده است.

تابع نمایی:

$$B(j; \theta) = \frac{\theta^{j-1}(1-\theta)}{1-\theta^{j^{max}}} \quad (9)$$

در توابع وزن‌دهی، j^{max} نشان‌دهنده حداکثر طول وقفه و معادل j^{max} در مدل (۴) است. تابع وزن نمایی تنها یک پارامتر برای تخمین دارد و از اختصار بیشتری نسبت به دو تابع بتا و آلمن نمایی برخوردار است، اگرچه در این حالت، وزن‌ها بصورت نزولی مقید شده‌اند.

مدل پایه مورد بررسی در این مقاله، مدل خودرگرسیون ساده در تواتر فصلی است. بطوریکه وقفه‌ها همانند متغیر هدف با تواتر فصلی وارد مدل می‌شوند. پیش‌بینی‌های چند گام به جلو در مدل پایه به روش مستقیم^۱ انجام می‌گیرد.

یکی از موضوعات مهم در رابطه با مدل‌های خودرگرسیون در سری‌های زمانی، انتخاب طول وقفه بهینه است. از آنجا که فیلتر وزن در رگرسیون میداس با انجام یک مسئله بهینه‌سازی روی وقفه‌ها برازش می‌گردد، لذا بحث پیدا کردن وقفه‌های بهینه در این مدل موضوعیت ندارد. طول وقفه برای مدل وزن‌دهی گام به گام و مدل پایه بصورت تجمعی و برابر با طول وقفه مدل میداس لحاظ شده است. تخمین ضرایب مدل‌های پایه و وزن‌دهی گام به گام براساس روش حداقل مربعات^۲، و برآورد ضرایب رگرسیون‌های میداس، مبتنی بر روش حداکثر راستنمایی^۳ انجام شده است. حداکثر تعداد وقفه‌های مؤثر در این مقاله براساس بهینه‌سازی انجام‌شده، ۵ فصل، معادل ۱۵ ماه، انتخاب شده است که معادل تعداد وقفه‌های مورد استفاده توسط کرمی و برکچیان (۱۳۹۳)^۴ است. بازه زمانی مشاهدات نرخ تورم، از تاریخ تیر ۱۳۶۹ تا ابتدای دی ۱۳۹۲ است.^۵ بازه

^۱ Direct

^۲ Ordinary Least Squares (OLS)

^۳ Maximum Likelihood Estimation (MLE)

^۴ در این مقاله، تعداد وقفه‌های مؤثر برای پیش‌بینی تورم، تا ۵ فصل شناسایی شده است.
^۵ شاخص قیمت کالاها و خدمات مصرف‌کننده از بانک مرکزی اخذ شده است.

زمانی زمستان ۱۳۸۹ تا ابتدای زمستان ۱۳۹۲ به عنوان دوره خارج از نمونه و مشاهدات ماقبل آن به عنوان مشاهدات نمونه در نظر گرفته شده است. قبل از برآورد ضرایب، تمامی سری‌های ماهانه و فصلی ابتدا از فیلتر فصلی‌زدایی Census X12 عبور کرده و سپس وارد مدل شده‌اند. پیش‌بینی‌های تورم برای یک تا چهار گام^۱ رو به جلو با تکنیک پنجره گسترش‌یابنده^۲ بدست آمده و برای مقایسه‌ی دقت پیش‌بینی‌ها با مدل پایه در هر گام پیش‌بینی از شاخص^۳ RMSFE استفاده شده است. در انتها، برای بررسی وجود اختلاف معنادار بین نتایج مدل‌های با تواتر متفاوت و مدل خودرگرسیون پایه، از آزمون دیبولد-ماریانو تغییر یافته، ارائه‌شده از جانب هاروی و همکاران^۴ (۱۹۹۷) بهره‌گرفته می‌شود.

۴. یافته‌ها و ارائه نتایج

در این مقاله، دقت پیش‌بینی^۲ مدل رگرسیون میداس و وزن‌دهی گام به گام با مدل پایه برآوردشده در تواتر ثابت فصلی مقایسه شده است. در مجموع، با احتساب^۳ تابع وزن متفاوت برای رگرسیون میداس،^۵ مدل برآورد شده است که در جدول (۱) نشان داده شده‌اند.

جدول (۱): الگوهای مورد بررسی در این مقاله

مشخصات مدل	گروه
رگرسیون میداس با تابع وزن بتا	الگوهای داده‌های با تواتر متفاوت
رگرسیون میداس با تابع وزن آلمن	
رگرسیون میداس با تابع وزن نمایی	
مدل وزن‌دهی گام به گام	مدل پایه در تواتر فصلی
پیش‌بینی به روش مستقیم	

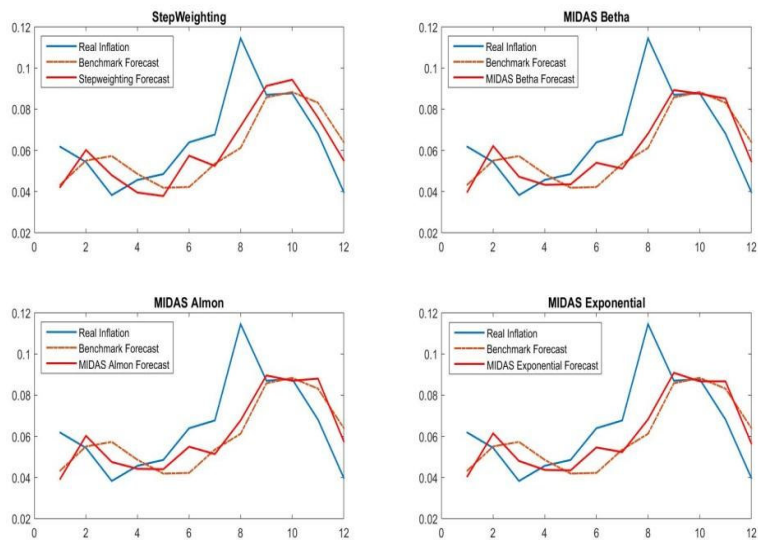
^۱ در اینجا هر گام یک فصل محسوب می‌شود.

^۲ Expanding Window

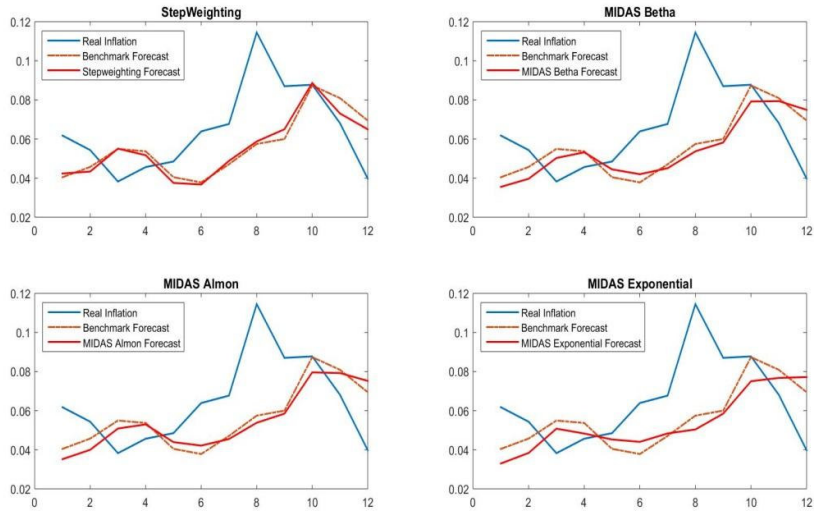
^۳ Root of Mean Squared Forecasting Error

^۴ Harvey, Leybourne and Newbold

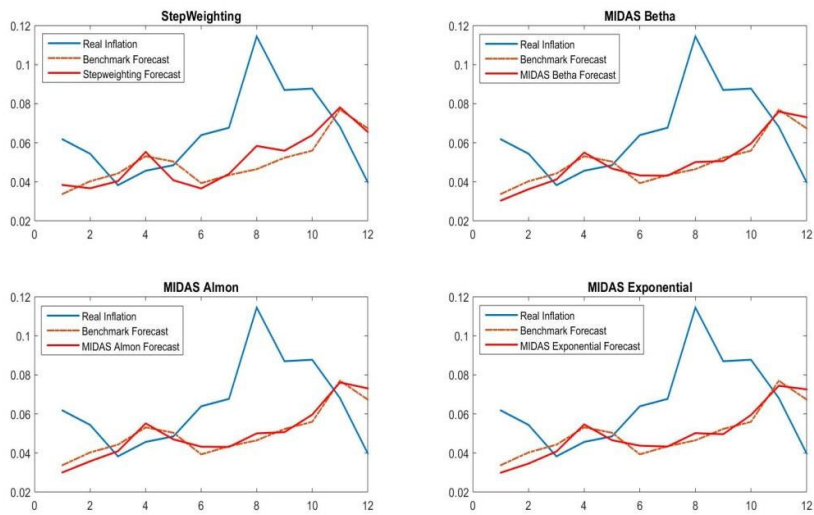
نتایج پیش‌بینی مدل‌های مورد بررسی برای یک تا چهار فصل آینده تورم، متناظر با بازه زمانی ۱۰:۸۹ تا ۹:۹۲، در کنار تورم محقق‌شده و پیش‌بینی مدل پایه به ترتیب در نمودارهای (۱)، (۲)، (۳) و (۴) ارائه شده است. همانطور که در نمودارها مشاهده می‌شود، هرچه گام‌های پیش‌بینی بلندتر می‌شود، دقت پیش‌بینی‌ها بطور قابل ملاحظه‌ای کاهش می‌یابد.



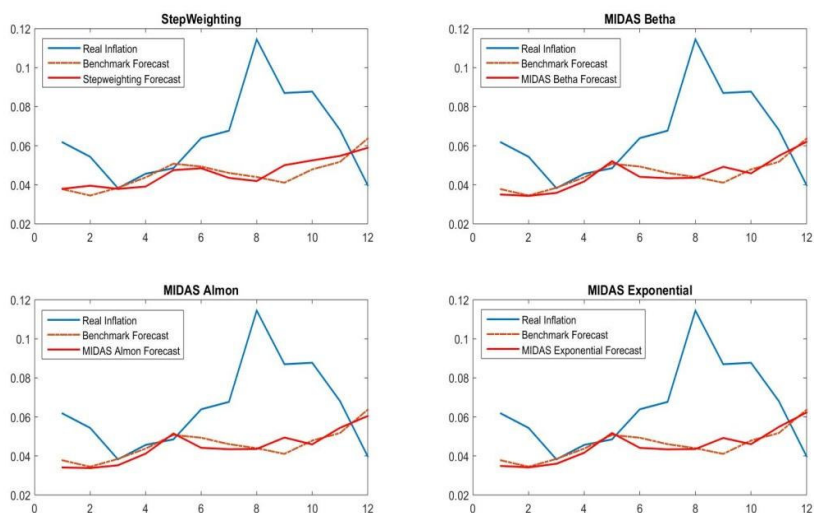
نمودار (۱): نتایج پیش‌بینی‌های یک گام به جلو



نمودار (۲): نتایج پیش‌بینی‌های دو گام به جلو



نمودار (۳): نتایج پیش‌بینی‌های سه گام به جلو



نمودار (۴): نتایج پیش‌بینی‌های چهار گام به جلو

منبع: یافته‌های پژوهش

به منظور سنجش دقت پیش‌بینی‌ها از شاخص $RMSFE$ استفاده می‌شود. هرچه عدد این شاخص کوچکتر باشد، نشان‌دهنده انحراف کمتر پیش‌بینی‌ها از واقعیت و به عبارت دیگر دقت بالاتر مدل در پیش‌بینی‌های خارج از نمونه است. نتایج شاخص $RMSFE$ نسبی بین مدل‌های داده‌های با تواتر متفاوت و مدل پایه در جدول (۲) گزارش شده است.

جدول (۲): نتایج درصد شاخص $RMSFE$ نسبی مدل‌های داده‌های با تواتر متفاوت و الگوی پایه

مدل	پیش‌بینی یک گام به جلو	پیش‌بینی دو گام به جلو	پیش‌بینی سه گام به جلو	پیش‌بینی چهار گام به جلو
رگرسیون میداس با تابع وزن بتا	۰/۸۵۲	۱/۰۶۹	۰/۹۹۶	۰/۹۹۳

۰/۹۹۲	۰/۹۹۹	۱/۰۶۸	۰/۸۷۶	رگرسیون میداس با تابع وزن آلمن
۰/۹۹۳	۱/۰۰۰	۱/۱۰۳	۰/۸۵۷	رگرسیون میداس با تابع وزن نمایی
*۰/۹۵۰	*۰/۸۸۴	*۰/۹۴۳	*۰/۷۸۵	مدل وزن دهی گام به گام

توضیحات جدول: در این جدول، دقت نسبی پیش‌بینی مدل‌های داده‌های با تواتر متفاوت نسبت به روش پایه مبتنی بر شاخص RMSFE ارائه شده است. هرچه عدد بدست آمده کوچکتر از ۱ باشد، نشان می‌دهد دقت مدل پیش‌بینی نسبت به مدل پایه بالاتر است و بالعکس. بازه زمانی زمستان ۱۳۸۹ تا ابتدای زمستان ۱۳۹۲ بعنوان دوره پیش‌بینی در نظر گرفته شده است. طول وقفه مدل‌های پیش‌بینی ۵ فصل انتخاب شده است. علامت ستاره نشان‌دهنده حداقل مقدار شاخص در هر گام پیش‌بینی بوده و بهترین مدل را از لحاظ دقت پیش‌بینی نمایان می‌سازد.

منبع: یافته‌های پژوهش

برای بررسی این موضوع که آیا پیش‌بینی مدل‌های مختلف اختلاف معناداری به لحاظ آماری با هم دارند یا خیر، از آزمون دیبولد-ماریانو تغییر یافته استفاده شده است. از آنجا که این آزمون به مقایسه مدل‌های پیش‌بینی بصورت دوجه‌دو در هر گام پیش‌بینی می‌پردازد، دقت عملکرد مدل‌های داده‌های با تواتر متفاوت با مدل پایه پیش‌بینی تورم بصورت جداگانه در هر گام پیش‌بینی مقایسه شده است. نتیجه این آزمون در جدول (۳) ارائه شده است.

جدول (۳) نتایج P-Value آزمون دیبولد-ماریانو تغییر یافته بین مدل‌های داده‌های با تواتر

متفاوت و الگوی پایه

مدل	پیش‌بینی یک گام به جلو	پیش‌بینی دو گام به جلو	پیش‌بینی سه گام به جلو	پیش‌بینی چهار گام به جلو
رگرسیون میداس با تابع وزن بتا	۰/۱۳	۰/۱۹	۰/۹۳	۰/۷۷

۰/۸۰	۰/۹۸	۰/۲۰	۰/۱۸	رگرسیون میداس با تابع وزن آلمن
۰/۷۷	۱/۰۰	۰/۱۹	۰/۱۳	رگرسیون میداس با تابع وزن نمایی
۰/۲۶	۰/۲۴	۰/۱۳	۰/۰۹**	مدل وزن‌دهی گام به گام

توضیحات جدول: آزمون دیبولد-ماریانو تبدیل‌یافته بررسی می‌کند که دقت پیش‌بینی‌های دو مدل، به لحاظ آماری اختلاف معنادار دارد یا خیر. علامت دو ستاره نشان‌دهنده رد فرضیه صفر آزمون (عدم وجود اختلاف آماری بین پیش‌بینی‌های دو مدل) در سطح معناداری ۱۰ درصد است.

منبع: یافته‌های پژوهش

نتایج جداول (۲) و (۳) بصورت زیر قابل ارائه است:

۱. در پیش‌بینی یک گام به جلو تورم، **مدل‌های داده‌های با تواتر متفاوت**، بطور قابل ملاحظه‌ای نسبت به مدل پایه فصلی عملکرد بهتر دارند. اگرچه این برتری، در گام‌های بلندتر، تا حدود زیادی محو شده است. بنابراین، این فرضیه که ورود اطلاعات با تواتر بالاتر در سمت متغیرهای توضیح‌دهنده موجب بهبود دقت پیش‌بینی‌ها می‌شود، تأیید شده و این مزیت بطور چشمگیری برای پیش‌بینی‌های یک گام به جلو تورم فصلی مشاهده می‌شود. در مطالعه‌ای که گایسلز و همکاران^۱ (۲۰۰۹) برای پیش‌بینی چنددوره‌ای تلاطم انجام داده‌اند، اینچنین نتیجه گرفته‌اند که در پیش‌بینی افق‌های زمانی بلندتر، عملکرد دقیق‌تر رگرسیون میداس بیشتر نمایان می‌شود. اما در این مقاله، رگرسیون میداس در مقایسه با مدل پایه پیش‌بینی تورم، که از اطلاعات تاریخی در تواتر فصلی استفاده می‌کند، در پیش‌بینی گام‌های بلندتر عملکرد دقیق‌تری ارائه نکرده است.

۲. در بین **مدل‌های داده‌های با تواتر متفاوت**، مدل وزن‌دهی گام به گام در مقایسه

^۱ Ghysels et al

با رگرسیون‌های میداس، در تمام گام‌های رو به جلو بهترین جایگاه را از نظر شاخص RMSFE کسب کرده است. عملکرد رگرسیون میداس، به عنوان الگویی متمایز و صرفه‌جو در وزن‌دهی به وقفه‌های ماهانه، متمایز از روش وزن‌دهی گام به گام نبوده و حتی در تمام گام‌ها، دقت پیش‌بینی آن کمتر از روش وزن‌دهی گام به گام بوده است. بنابراین، اختصار در تعداد پارامترهای برآوردی چندان به کمک پیش‌بینی تورم نیامده و مزیتی برای رگرسیون میداس نسبت به مدل وزن‌دهی گام به گام ایجاد نکرده است. به عبارت دیگر در این حالت، خطای تصریح بر خطای تخمین پیشی گرفته است. نتیجه بدست آمده در این مقاله در تقابل با نتایج بدست آمده در مقاله آرمستو و همکاران (۲۰۱۰) است. در آن مقاله که برای اقتصاد امریکا انجام شده است، دقت پیش‌بینی‌های میداس همواره بالاتر از دقت پیش‌بینی‌های مدل پیش‌بینی گام به گام بوده است. البته در آن تحقیق، برای پیش‌بینی تورم از متغیرهای توضیح‌دهنده دیگر غیر از اطلاعات تاریخی تورم نیز استفاده شده است.

۳. اختلاف معناداری بین دقت عملکرد رگرسیون‌های میداس با اوزان متفاوت ملاحظه نمی‌گردد. با این حال، تابع وزن بتا در بیشتر پیش‌بینی‌ها عملکردی به نسبت دقیق‌تر از دیگر توابع وزن‌دهی داشته است. باید توجه داشت که عملکرد توابع وزن‌دهی بسته به متغیر هدف برای پیش‌بینی، نوع داده‌ها و تواتر ترکیب بین داده‌های مورد استفاده متفاوت است. مثلاً برای پیش‌بینی تلاطم در بازارهای مالی به دلیل وجود حافظه بلندمدت، استفاده از تابع وزن هیپربولیک با یک پارامتر برآوردی، عملکرد خوبی در میان توابع مطرح‌شده در این مقاله داشته است. (گایسلز و همکاران (۲۰۰۹))

۴. نتایج آزمون دیبولد-ماریانو تغییر یافته نشان می‌دهد که به غیر از مدل پیش‌بینی گام به گام، آن هم در پیش‌بینی یک گام به جلو و در سطح معناداری ۱۰ درصد، پیش‌بینی‌های دیگر **مدل‌های داده‌های با تواتر متفاوت**، به لحاظ آماری اختلاف معنادار با مدل پایه ندارد.

۵. نتیجه‌گیری

این مطالعه به بررسی دقت مدل‌های پیش‌بینی تورم در دو گروه **مدل‌های داده‌های با تواتر متفاوت** و مدل‌های با تواتر فصلی پرداخته است. موافق با تئوری، **مدل‌های داده‌های با تواتر متفاوت** نسبت به مدل با تواتر فصلی از عملکرد دقیق‌تری برخوردارند. این بدین معنی است که پیش‌بینی فصلی نرخ تورم براساس اطلاعات تاریخی ماهانه نرخ تورم می‌تواند به بهبود دقت پیش‌بینی‌ها کمک کند. به عبارت دیگر، از آنجا که اطلاعات ماهانه نسبت به اطلاعات فصلی، مجموعه اطلاعاتی غنی‌تری بوجود می‌آورند، استفاده از آنها در مدل‌های خودرگرسیون پیش‌بینی تورم به بهبود دقت نتایج منجر می‌شود.

تحقیق حاضر همچنین نشان می‌دهد که استفاده از رگرسیون میداس به جای مدل ساده پیش‌بینی گام به گام، مزیتی برای پیش‌بینی‌های خارج از نمونه ایجاد نکرده است. این بدان معناست که تخمین تمام پارامترهای مرتبط با وقفه‌های ماهانه بصورت جداگانه و براساس تکنیک سنتی حداقل مربعات، نتایج دقیق‌تری نسبت به مدل رگرسیون میداس، که یک مدل غیرخطی با تعداد پارامتر محدود است، در بر داشته است. با این حال، ذکر این نکته ضروری است که بطور کلی، دقت پیش‌بینی مدل‌های با تواتر متفاوت نسبت به مدل مرسوم پیش‌بینی تورم (مدل پایه)، که در تواتر فصلی برآورد می‌گردد، به لحاظ آماری اختلاف قابل توجهی ندارد. بنابراین، اگرچه استفاده از وقفه‌های ماهانه نرخ تورم منجر به افزایش دقت پیش‌بینی‌های فصلی تورم می‌گردد، این افزایش دقت فاحش نبوده است.

منابع

- Andreou, E., Ghysels, E., & Kourtellos, A. (2010). Regression Models with Mixed Sampling Frequencies. *Journal of Econometrics*, 158(2), 246-261.

- Andreou, E., Ghysels, E., & Kourtellos, A. (2013). Should macroeconomic forecasters use daily financial data and how? *Journal of Business & Economic Statistics*, 31(2), 240-251.
- Armesto, M. T., Engemann, K. M., & Owyang, M. T. (2010). Forecasting with Mixed Frequencies. *Federal Reserve Bank of St. Louis Review*, 92(6), 521-536.
- Atrianfar, H., & Barakchian, S. M. (2014). Evaluation of the Performance of Combined Methods in Real-time Forecasting of Inflation in Iran. *Money and Banking Research*, 6(18), 23-57. (In Persian)
- Barakchian, S. M., & Rezaei, M. (2015). Introduction and Performance Comparison of some Common Multi-period VaR Forecasting Methods: A Case Study of the Tehran Stock Exchange. *Iranian Journal of Economic Research*(60), 1-35. (In Persian)
- Barakchian, S. M., Karami, H., & Bayat, S. (2014). Forecasting Inflation Rate of Iran Using Phillips Curve. *MBRI Working Paper*(93016). (In Persian)
- Bayat, M., & Noferesti, M. (2015). *Applied Time Series Econometrics: Mixed Frequency Data Sampling Model*. Hamedan: Noor-e-Elm. (In Persian)
- Bayat, S., & Barakchian, S. M. (2014). Inflation Forecasting Using Disaggregation of CPI Component. *Journal of Monetary and Banking Research*, 7(19), 44-59. (In Persian)
- Ghysels, E., Rubia, A., & Valkanov, R. (2009). Multi-Period Forecasts of Volatility: Direct, Iterated, and Mixed-Data Approaches. *SSRN Working Paper*(1344742).
- Ghysels, E., Santa-Clara, P., & Valkanov, R. (2005). There Is A Risk-Return Tradeoff After All. *Journal of Financial Economics*, 76, 509-548.
- Ghysels, E., Santa-Clara, P., & Valkanov, R. (2006). Predicting volatility: getting the most out of return data sampled at different frequencies. *Journal of Econometrics*, 131, 59-95.

- Ghysels, E., Sinko, A., & Valkanov, R. (2007). MIDAS Regressions: Further results and new directions. *Econometric Reviews*, 26(1), 53-90.
- Harvey, D., Leybourne, S., & Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of forecasting*, 13, 281-291.
- Heidari, H. (2011). An Alternative VAR Model for Forecasting Iranian Inflation: An Application of Bewley Transformation. *Iranian Journal of Economic Research*, 16(46), 77-96. (In Persian)
- Karami, H., & Barakchian, S. M. (2014). Evaluation of Autoregressive Models in Forecasting Inflation Rate of Iran. *MBRI Working Paper*(9212). (In Persian)
- Molabahrami, A., Khodavaisi, H., & Hossaini, R. (2013). Forecasting Inflation based on Stochastic Differential Equations and Alternative Models (A Comparative Study). *The Economic Research (Scientific Research Quarterly)*, 13(1), 25-46. (In Persian)
- Moshiri, S. (2000-2001). Forecasting Iranian Inflation Rates Using Structural, Time Series, and Artificial Neural Networks Models. *Tahghighat-e-eghtesadi*(58), 147-184. (In Persian)
- Nijman, T., & Palm, F. (1990). Parameter identification in ARMA processes in the presence of regular but incomplete sampling. *Journal of Time Series Analysis*, 11(3), 239-248.
- Noferesti, M., & Bayat, M. (2015). Forecasting Iranian's Economic Growth Using Mixed Frequency Data Sampling Technique. *Quarterly Journal of Economics and Modeling Shahid Beheshti University*, 4(14 & 15). (In Persian)
- Shahikitash, M., Molaei, S., & Hallajzadeh, Z. (2014). Forecasting Inflation and Price Index with Neural Network. *Quarterly Journal of The Macro and Strategic Policies*, 1(4), 51-67. (In Persian)

- Silvrtrini, A., & Veredas, D. (2008). Temporal aggregation of univariate and multivariate time series models: A survey. *Journal of Economic Surveys*, 22(3), 458-497.
- Taiebnia, A., Amiri, H., & Ravishi, F. (2014). The New Keynesian Phillips Curve and Forecasting Inflation. *Journal of Planning and Budgeting*, 18(4), 3-26. (In Persian)
- Zarra-Nezhad, M., & Hamid, S. (2009). Prediction of Inflation Rates in Iran Using Dynamic Artificial Neural Network (Time Series Approach). *Quarterly Journal of Quantitative Economics*,