

مقایسه دقت مدل‌های فرابتکاری و اقتصادسنجی در پیش‌بینی سری- های زمانی مالی دارای حافظه بلندمدت (مطالعه موردی؛ شاخص سهام صنعت سیمان در ایران)

فرناز بروزین پور^۱، سیدبابک ابراهیمی^۲، سید محمد هاشمی نژاد^{۳*}، حامد نصر اصفهانی^۴

۱. استادیار دانشکده مهندسی صنایع دانشگاه علم و صنعت، ایران
۲. دانشجوی دکترا مهندسی صنایع، دانشگاه علم و صنعت، ایران
۳. دانشجوی دکترا مدیریت مالی دانشگاه تهران، ایران
۴. کارشناسی ارشد مهندسی و مدیریت ساخت دانشگاه علم و صنعت، ایران

(تاریخ دریافت مقاله: ۱۳۸۹/۱۲/۱۹، تاریخ پذیرش نهایی مقاله: ۱۳۹۰/۴/۲۴)

چکیده

داده‌های با تناوب بالا نوع خاصی از نامانایی دارند که به آن نامانایی کسری گفته می‌شود. این ویژگی سبب پدیدآمدن حافظه بلندمدت در سری‌های زمانی مالی با تناوب بالا می‌شود. در این نوشتار ابتدا وجود حافظه بلندمدت در سری زمانی صنعت سیمان بررسی شده و وجود آن در سطح اطمینان بالایی توسط دو آزمون R/S و GPH تأیید می‌شود. در ادامه، دقت مدل‌های پیش‌بینی سری‌های زمانی مالی نظری، ARMA و GARCH که ویژگی حافظه بلندمدت را در مدل‌سازی سری زمانی در نظر نمی‌گیرند و مدل‌هایی مثل FIGARCH و ARFIMA، که این ویژگی را مدنظر قرار می‌دهند، با روش نوین فرابتکاری ارایه شده که ترکیبی از الگوریتم جستجوی هارمونی و سری‌های زمانی فازی وزن‌دار می‌باشد به روش پنجره غلتان و با استفاده از معیار ریشه میانگین توان دوم خطاهای (RMSE) در بازه‌های زمانی مختلف مورد مقایسه قرار می‌گیرد. نتایج حاصل نشان می‌دهند که روش فرابتکاری ارایه شده در تمامی بازه‌های زمانی نتیجه بهتری از مدل‌های متداول اقتصادسنجی ارایه می‌دهد.

واژه‌های کلیدی: بازده، تلاطم، حافظه بلندمدت، جستجوی هارمونی، ARFIMA، FIGARCH

JEL Classification: C15, C22, C 53

مقدمه

هنگامی که مشاهدات گذشته با مشاهدات در آینده دور همبستگی دارند و رابطه آنها غیرقابل چشم پوشی است سری زمانی مورد مطالعه دارای ویژگی حافظه بلندمدت است و تشخیص این الگو کاربردهای مهمی برای خرید و فروش های کوتاه مدت و همچنین استراتژی سرمایه گذاری بلندمدت دارد؛ زیرا تصمیمات سرمایه گذاری نسبت به دامنه زمانی مورد بررسی حساس هستند و این تصمیمات وابسته به میزان حافظه بلندمدت خواهند بود. حافظه بلندمدت موجب وابستگی غیرخطی در گشتاور اول توزیع بازده می گردد و در دینامیک سری زمانی پارامتری را تولید می نماید که قابلیت پیش بینی دارد. از این پارامتر در ادبیات مالی با عنوان پارامتر حافظه ای بلندمدت (d) نام برده می شود [۱].

از آنجا که حافظه بلندمدت موجب وابستگی بازده دارایی با بازده های قبلی (دوره $t-k$ و t) می شود، نشان دهنده وجود پارامتری قابل پیش بینی در دینامیک سری زمانی است. وجود این ویژگی دلیلی بر رد شکل ضعیف فرضیه کارایی بازار است. مطابق فرضیه بازار کارا قیمت دارایی ها نباید با استفاده از داده های قیمت دوره های گذشته قابل پیش بینی باشد. یکی از مهم ترین مدل های غیرخطی که برای پیش بینی و تبیین رفتار تلاطم ها در بازار های مالی استفاده می شود، مدل های GARCH است و بسته به اینکه به تنها یکی مدل سازی سری زمانی بازدهی سهام صورت پذیرد یا اینکه تلاطم های آن نیز با لحظه نمودن حافظه بلندمدت در نظر گرفته شود، روش تحلیلی مورد استفاده می تواند خانواده ARMA بوده یا به صورت FIGARCH تغییر یابد [۱][۲].

تمرکز اصلی این مقاله بر ارایه یک مدل فرآبتكاری از ترکیب الگوریتم جستجوی هارمونی^۱ و سری های زمانی فازی وزن دار و مقایسه دقت پیش بینی آن با مدل های مختلف استوار است. در این راستا در فواصل زمانی مختلف مدل ها را مورد ارزیابی قرار داده و بهترین مدل برای پیش بینی انتخاب می شود. سؤالی که در این پژوهش طرح و به آنها پاسخ داده می شود، می توان در قالب این پرسش بیان نمود که عملکرد مدل های مختلف در

1. Harmony Search

پیش‌بینی شاخص سهام صنعت سیمان چگونه است؟ پاسخ به این پرسش نوع برخورد ما را در مدل‌سازی بازده و تلاطم مشخص می‌سازد و این سؤال را پیش رو قرار می‌دهد که برای کسب بهترین نتایج در پیش‌بینی، کدام‌یک از مدل‌های مورد استفاده نتیجه مطلوب تری را به همراه دارند.

در این مقاله نیز ابتدا مروایی بر پیشینه تجربی پژوهش‌هایی که به مدل‌سازی و مقایسه دقت پیش‌بینی مدل‌های مختلف پرداخته‌اند، صورت می‌گیرد. سپس پایه‌های ساخت مدل فرآبتكاری پیشنهادی به تفصیل توضیح داده می‌شود. همچنین به تحلیل تجربی و مقایسه عملکرد مدل فرآبتكاری ارایه شده و مدل‌های ARFIMA، GARCH، ARMA، FIGARCH در سهام صنعت سیمان و با استفاده از برنامه‌نویسی پنجره غلتان در نرم‌افزار S-PLUS و معیار RMSE در بازه‌های زمانی متفاوت پرداخته و مدلی که بالاترین عملکرد را در پیش‌بینی دارد در هر یک از شرایط تعیین می‌شود.

پیشینه‌ی پژوهش

در حوزه اقتصادسنجی مدل‌های فراوانی برای پیش‌بینی سری‌های زمانی که دارای ویژگی حافظه بلندمدت یا فاقد آن بوده‌اند، معرفی گشته که از آن جمله می‌توان به مدل‌های ARFIMA، ARMA، GARCH و FIGARCH اشاره کرد. اما استفاده از مدل‌های فرآبتكاری و فازی برای پیش‌بینی به کمتر از یک دهه باز می‌گردد که بیشتر بر محوریت الگوریتم ژنتیک استوار بوده است. از سوی دیگر مدل‌های اقتصادسنجی برای پیش‌بینی نیاز به داده‌های زیادی دارند در نتیجه سونگ و چیسم^۱ [۱۹۹۳] تئوری سری‌های زمانی فازی را مطرح ساختند. بر اساس این تئوری چن^۲ [۱۹۹۶] مدلی را برای پیش‌بینی پذیرش دانشجو در دانشگاه آلاما ارایه نمود، که این مدل از لحاظ محاسبات نسبت به مدل پیشین خود ساده‌تر بوده و از دقت بالاتری نیز برخوردار بود. مدل ارایه شده توسط

1. Song & Chissom
2. Chen

چن پایه بسیاری از مطالعات مربوط به سری‌های زمانی فازی است. هیو^۱ در سال ۲۰۰۵، مدل چن را توسعه داده و مدلی بر اساس سری‌های زمانی فازی وزن‌دار ارایه می‌دهد و از آن برای پیش‌بینی قیمت سهام تایوان استفاده می‌نماید، نتایج نشان‌دهنده بهبود دقت پیش‌بینی بود [۱۴].

پس از این مدل‌ها پژوهش‌های بیشتری انجام شد، که یکی از این مسایل تعیین بازه‌های مناسب جهت استفاده در مدل‌های پیش‌بینی است. هوارگ^۲ (۲۰۰۱) در مقاله‌ی خود به این نکته اشاره کرده است که بازه‌های متفاوت می‌توانند نتیجه‌های پیش‌بینی متفاوتی را در پی داشته باشد و برای دستیابی به دقت پیش‌بینی بهتر، باید بازه‌های مناسبی تعیین نمود. برای رسیدن به چنین هدفی بازه‌های پیش‌بینی هیچ محدودیتی از لحاظ طول ندارند و باید با توجه به ماهیت داده‌ها تعیین شوند و به طور مناسب بر روی داده‌ها برازش شوند. برای رسیدن به چنین هدفی هوارگ برای اولین بار از الگوریتم‌های فرالبتکاری استفاده نمود [۱۳]. سائزور و همکاران^۳ (۲۰۰۵)، ابتدا به معرفی چهار نوع روند کلی پرداختند که شامل روند درازمدت، روند فصلی، روند سینوسی و روند نامنظم بود. سپس به بررسی دقیق تر روند دراز مدت پرداخته و روشی را برای تشکیل ماتریس روابط فازی در این نوع روند ارایه نمودند تا پیش‌بینی حاصل دقت بهتری پیدا کند [۱۸]. لی^۴ و همکاران (۲۰۰۶)، روشی برای حل مسایل پیش‌بینی با استفاده از سری‌های زمانی با مرتبه‌ی بالا و دو شاخصه ارایه دادند که از آن برای پیش‌بینی سری‌های زمانی مربوط به TAIEX و درجه حرارت روزانه-ی تایپه و تایوان استفاده نمودند [۱۶]. لی و همکاران در سال‌های ۲۰۰۷ و ۲۰۰۸ نیز به ترتیب با استفاده از الگوریتم‌های فرالبتکاری ژنتیک و شبیه‌سازی تبرید مدل‌هایی برای پیش‌بینی درجه حرارت و شاخص بورس تایوان ارایه دادند [۵][۶]. چنگ^۵ و همکاران (۲۰۰۸) [۱۲]، با ارایه یک نوع جدید بازه‌بندی و همچنین با وزن‌دهی به روابط

1. Hui

2. Huarng

3. Tsaur

4. Lee

5. Cheng

فازی توانستند، بهبود مناسبی را در مسائل پیش‌بینی فازی ارایه دهنند. پارک^۱ و همکاران [۷] از الگوریتم فراابتکاری PSO برای پیش‌بینی شاخص بورس تایوان و داده‌های شاخص KOPSI 200 استفاده کردند. وانگ^۲ و همکاران (۲۰۱۰) [۸] نیز مقایسه‌ای بین روش‌های فازی و مدل‌های ARIMA و ARIMA-ARFIMA و FIGARCH از دقت مدل‌های فازی و در پیش‌بینی بلندمدت مدل‌های ARIMA-GARCH و شبکه‌های عصبی و کارایی بهتری برخوردارند. از پژوهش‌های انجام شده در ایران نیز می‌توان به مشیری و فروتن (۱۳۸۳) اشاره کرد، با استفاده از مدل‌های ARIMA-GARCH، و شبکه‌های عصبی به پیش‌بینی قیمت جهانی نفت برای یک دوره زمانی ۷۰۰ روزه پرداختن سپس نتایج را با استفاده از معیارهای MSE، MAE و RMSE مقایسه نموده و نشان دادند که مدل شبکه عصبی از توانایی پیش‌بینی بالاتری نسبت به سایر مدل‌ها برخوردار است. در این پژوهش نتایج آماره دیبولد و ماریانو نیز تفاوت معناداری در دقت پیش‌بینی این مدل‌ها را نشان می‌دهد [۳].

بررسی دقیق مطالعات تجربی انجام شده نشان می‌دهد، الگوریتم ارایه شده که ترکیبی از الگوریتم جستجوی هارمونی و سری‌های زمانی فازی وزن‌دار است تا به حال در پیش‌بینی سری‌های زمانی مورد استفاده قرار نگرفته است. در کشور نیز (بهخصوص در صنعت سیمان که همواره از صنایع تأثیرگذار در بورس بوده است) مطالعه‌ای که به مقایسه عملکرد مدل‌های پیش‌بینی با در نظر گرفتن حافظه بلندمدت بپردازد، انجام نشده است و از این لحاظ توسعه نظری و به دنبال آن تحلیل تجربی انجام شده در این مقاله گامی ارزنده به شمار می‌آید.

حافظه بلندمدت

در مدل‌سازی یک سری زمانی، ابتدا باید اطمینان حاصل کرد که سری زمانی مانا باشد. در سری‌های زمانی مالی، نامانایی ناشی از این واقعیت است که سطح ثابتی برای بازده‌ها وجود

1. Park

2. Wong

ندارد. در ادبیات سری‌های زمانی، چنین سری زمانی نامانایی، سری زمانی نامانای دارای ریشه واحد نامیده می‌شود. برای آزمون ریشه واحد، با توجه به این که داده‌های مورد استفاده روزانه هستند؛ بنابراین لازم است وجود حافظه بلندمدت آزمون شود که آزمون GPH بیانگر وجود یا نبود ریشه واحد نیز است. آزمون حافظه بلندمدت به روش آزمون که توسط گوکی، پورتر و هوداک^۱ [۱۰] ارایه شده است و آماره R/S تعديل یافته صورت می‌پذیرد؛ زیرا آماره R/S تعریف شده [۱۵] برای وابستگی‌های با دامنه کوتاه استوار^۲ نیست و به منظور نشان دادن وابستگی‌های کوتاه‌مدت در سری زمانی، به ازای $T = 1, 2, \dots, t$ ، آماره R/S تعديل شده به کار گرفته می‌شود. در این آزمون‌ها فرضیه صفر نبود حافظه بلندمدت و فرضیه مقابله وجود حافظه بلندمدت در سری زمانی است. بنابراین؛ چنانچه آماره آزمون اختلاف معناداری از صفر نداشته باشد، فرضیه صفر یعنی نبود حافظه بلندمدت را نمی‌توان رد کرد.

چارچوب مدل فرآابتکاری ارایه شده

در راستای مدل‌سازی و پیش‌بینی شاخص قیمت بازدهی سهام صنعت سیمان از مدل‌های ARMA و GARCH به عنوان مدل‌های پر کاربرد اقتصادسنجی که قادر به در نظر گرفتن ویژگی حافظه بلندمدت نیستند، استفاده شده است. همچنین از مدل‌های ARFIMA و FIGARCH به عنوان مدل‌هایی که قادر به مدل‌سازی حافظه بلندمدت هستند، استفاده شده است. پایه‌های تئوریک و ساختکار مدل فرآابتکاری ارایه شده که ترکیبی از الگوریتم متاهیوریستیک جستجوی هارمونی و سری‌های زمانی فازی است به تفصیل در این بخش توضیح داده خواهد شد.

1. Geweke, Porter, Hudak
2. Robust

سری زمانی فازی

همان‌طور که در ادبیات پژوهش اشاره شد، سونگ و چیسم [۱۹]، تئوری سری‌های زمانی فازی را مطرح ساخته و در مقاله خود اصولی را مطرح نمودند که تمامی مدل‌های تعیین داده شده بر مبنای این اصول هستند.

تعریف ۱) $f_i(t) = 0, 1, 2, \dots$ (مقادیر متغیر در لحظه‌ی t) را زیر مجموعه‌ای از اعداد حقیقی در نظر بگیرید و همچنین دامنه‌ی تغییرات متغیر توسط مجموعه‌های فازی $f_1(t), f_2(t), \dots, f_j(t)$ افزایش شده باشد، در چنین شرایط اگر مجموعه‌ای از $y(t)$ باشد، در نتیجه $F(t)$ یک سری زمانی فازی بر روی $y(t)$ است.

تعریف ۲) اگر یک رابطه‌ی فازی $R(t-1, t)$ به صورت $F(t-1) = F(t-1) \circ R(t-1, t)$ و "و" نشانگر عملگر max-min باشد و $F(t-1)$ هر کدام یک مجموعه‌ی فازی باشد، در نتیجه می‌توان گفت توسط $F(t-1)$ به وجود آمده است. رابطه‌ی فازی $F(t)$ و $F(t-1)$ به صورت رابطه (۱) نشان داده می‌شود:

$$F(t-1) \rightarrow F(t) \quad (1)$$

تعریف ۳) اگر فرض کنیم $F(t)$ و $F(t-1)$ به ترتیب برابر با A_i و A_j باشند، رابطه-ی بین $F(t)$ و $F(t-1)$ به عنوان یک رابطه‌ی منطقی فازی^۱ (FLR) مطرح می‌شود که در این صورت $A_i \rightarrow A_j$ یک رابطه‌ی منطقی فازی است که در آن A_i به عنوان دست چپ^۲ (LHS) رابطه و A_j به عنوان دست راست^۳ (RHS) رابطه تعیین می‌شود. تعریف ۴) تمام روابط فازی که دارای طرف چپ یکسان باشند؛ می‌توان در یک دسته قرار داد.

-
1. Fuzzy logical relationship
 2. Left hand side
 3. Right hand side

تعریف ۵) فرض کنید $F(t - 1)$ توسط $F(t)$ به وجود آمده باشد و برای هر t داشته باشیم:

$F(t) = R(t - 1, t)$ و $R(t - 1, t) = F(t) \cdot R(t - 1, t)$

یک سری زمانی مستقل از زمان خواهد بود و در غیر این صورت وابسته به زمان است.

الگوریتم جستجوی هارمونی

یکی از الگوریتم‌های فرآبتكاری الگوریتم جستجوی هارمونی است که اولین بار در سال ۲۰۰۱ توسط گیم و همکاران ارایه شد و با توجه به نتایج بدست آمده از مقاله‌های ارایه شده و حل مسایل گوناگون، الگوریتمی کارا و سریع شناخته شده است [۹]. مانند سایر الگوریتم‌های فرآبتكاری که بیشتر آن‌ها از طبیعت و محیط اطراف الهام گرفته و گستردۀ شده‌اند (مانند الگوریتم ژنتیک و کلونی مورچه‌ها)، الگوریتم جستجوی هارمونی هم با توجه به هنر موسیقی و اینکه چگونه حس لذت گوش‌دادن به موسیقی را برای شنونده ایجاد کنیم، ایجاد و توسعه داده شده است. به عبارت دیگر ایجاد و ساخت یک قطعه موسیقی تشابه زیادی به پیدا کردن یک جواب بهینه برای یک مسئله‌ی ریاضی دارد. از یک طرف یک موسیقی‌دان در پی ایجاد و ساخت بهترین هارمونی ممکن است و آن مسئله هم در پی ایجاد و بدست دادن بهترین پاسخ برای یک مسئله است. وقتی که موسیقی‌دانی می‌خواهد یک قطعه موسیقی بسازد، او چندین گزینه برای ساخت در پیش روی دارد:

- نواختن موسیقی معروف بدون تغییر و به همان ترتیبی که در ذهن دارد.
 - نواختن آهنگی شبیه موسیقی معروف، در واقع با تغییر دادن جزئی آن چیزی که وجود دارد.
 - ایجاد یک قطعه موسیقی به‌طور کامل جدید با نت‌هایی جدید.
- الگوریتم جستجوی هارمونی نیز پنج مرحله اصلی دارد که عبارتند از:

۱) تعریف تابع هدف و پارامترهای الگوریتم ($'HMCR$, $'PAR$, $'BW$)
در ابتدا برای شروع حل با این الگوریتم، تابع هدف و پارامترهای الگوریتم مشخص می‌شوند. به عنوان مثال در این مطالعه به دنبال مینیمم کردن RMSE هستیم:

$$f(X) = RMSE = \sqrt{\frac{\sum_{t=1}^n [\text{forecast}(t) - \text{actual}(t)]^2}{n}} \quad (2)$$

در ادامه به تعریف پارامترهای PAR و HMCR که دو پارامتر بین صفر و یک هستند و به ترتیب احتمال در نظر گرفتن متغیر از حافظه ماتریس و احتمال تغییر در متغیر انتخاب شده از حافظه ماتریس به اندازه‌ی تصادفی است، می‌پردازیم. به طور معمول مقدار HMCR حدود ۰/۹۵ تا ۰/۷۰ اختیار می‌شود و پارامتر PAR مقداری در حدود ۰/۱ تا ۰/۵ می‌گیرد. برای تعیین مقدار تغییر بر روی متغیر انتخاب شده از حافظه ماتریس، پارامتر دیگری به نام BW تعریف می‌شود.

۲) ایجاد ماتریس حافظه: در مرحله دوم یک ماتریس حافظه^۴ از چندین راه حل یا هارمونی تشکیل می‌شود. شکل کلی این ماتریس حافظه به صورت زیر است:

$$HM = \begin{bmatrix} x_1^1 & \dots & x_N^1 \\ | & \ddots & | \\ x_1^{HMS} & \dots & x_N^{HMS} \end{bmatrix}_{HMS \times N}$$

تعداد ردیف‌ها در این ماتریس حافظه به تعداد^۵ HMS است که هر ردیف به معنی یک راه حل یا جواب مسئله است. در این ماتریس تعداً متغیرها N است. این ماتریس حکم موسیقی‌های معروفی را دارد که یک موسیقی‌دان قصد دارد، بدون تغییر آن‌ها را بنوازد. هر ردیف در حکم یک هارمونی یا قطعه موسیقی است که به احتمال زیاد هیچ کدام از این هارمونی‌ها یا جواب‌ها بهترین هارمونی یا جواب ممکن نیست. با توجه به تابع برازش، مقدار برازش یا ارزش هر کدام از این راه حل‌ها را به دست می‌آوریم.

-
1. Harmony Memory Considering Rate
 2. Pitch Adjusting Rate
 3. Band Width
 4. Harmony Memory
 5. Harmony Memory Size

$$\begin{bmatrix} x_1^1 & x_2^1 & \dots & x_{N-1}^1 & x_N^1 \\ x_1^2 & x_2^2 & \dots & x_{N-1}^2 & x_N^2 \\ \vdots & \dots & \dots & \dots & \vdots \\ x_1^{HMS-1} & x_2^{HMS-1} & \dots & x_{N-1}^{HMS-1} & x_N^{HMS-1} \\ x_1^{HMS} & x_2^{HMS} & \dots & x_{N-1}^{HMS} & x_N^{HMS} \end{bmatrix} \Rightarrow \begin{array}{l} f(\mathbf{x}^1) \\ f(\mathbf{x}^2) \\ \vdots \\ f(\mathbf{x}^{HMS-1}) \\ f(\mathbf{x}^{HMS}) \end{array}$$

(۳) تولید یک راه حل یا هارمونی جدید: برای ایجاد یک هارمونی یا راه حل جدید مانند الگوریتم ژنتیک به چند عملگر احتیاج داریم و تک تک به ایجاد متغیرها می پردازیم. برای ایجاد مقدار برای هر متغیر \mathcal{E} ، ابتدا یک عدد تصادفی بین صفر و یک تولید می کنیم این عدد تصادفی با HMCR مقایسه می شود و اگر کوچکتر از آن باشد، یک مقدار برای متغیر \mathcal{E} از ماتریس حافظه و از ستون \mathcal{E} انتخاب و در غیر این صورت یک مقدار تصادفی از فضای جستجو برای متغیر \mathcal{E} انتخاب می شود. در صورتی که از ماتریس حافظه یک مقدار انتخاب شد، سپس عدد تصادفی دیگری تولید و با PAR مقایسه می شود؛ در صورتی که عدد تصادفی کوچکتر از PAR باشد، این متغیر انتخاب شده از ماتریس حافظه به مقدار کوچکی با توجه به رابطه (۳) تغییر پیدا می کند. برای تعیین مقدار تغییر بر روی متغیر انتخاب شده از حافظه ماتریس، پارامتر دیگری به نام bw تعریف می شود که با توجه به رابطه (۳) مقدار متغیر جدید به دست می آید:

$$x_{new} = x_{old} + b_{range} \times \mathcal{E} \quad (3)$$

در این رابطه \mathcal{E} یک عدد تصادفی در بازه $[0, 1]$ است.

(۴) بهروز کردن ماتریس حافظه: بهمین صورت تمام متغیرهای یک جواب یا هارمونی ایجاد و ارزش یا برازش آن هارمونی با توجه به تابع برازش محاسبه شده و با بدترین هارمونی موجود در حافظه ماتریس مقایسه می شود. در صورت بهتر بودن از بدترین هارمونی موجود در حافظه ماتریس، هارمونی جدید جایگزین هارمونی قبلی می شود.

(۵) شرط توقف: شرط توقف الگوریتم به چند صورت می تواند تعیین شود. در بیشتر موارد شرط توقف، رسیدن به مقدار بهینه مورد نظر است. از دیگر شروط می توان به تغییر

نکردن بهترین هارمونی موجود در ماتریس حافظه به تعداد تکرارهای مشخص اشاره کرد.

به این ترتیب با تکرار زیاد این الگوریتم، به مرور به مقدار بینه نزدیک خواهیم شد.

روش پیش‌بینی با استفاده از سری‌های فازی زمانی و الگوریتم جستجوی هارمونی
مزیت استفاده از الگوریتم‌های فرآیندکاری در پیش‌بینی سری‌های زمانی فازی در تعیین طول‌های متغیر و بهبود یافته برای مجموعه جهانی است؛ بنابراین استفاده از این الگوریتم‌ها باعث کم شدن قابل ملاحظه خطای پیش‌بینی خواهد شد. روند کلی کار در زیر بیان شده است:

ابتدا فضای مسئله (مجموعه جهانی^۱ U) را بر اساس D_{\min} و D_{\max} و به صورت رابطه (۴) تعریف می‌کنیم:

$$U = [D_{\min} - D_1, D_{\max} + D_2] \quad (4)$$

در گام بعد به تولید ماتریس حافظه می‌پردازیم. برای مثال با فرض $U = [13000, 20000]$ مقدار $D_{\min} = 13055$ و $D_{\max} = 19337$

می‌شود. مجموعه U به ۷ بازه افزایش می‌شود:

$$\begin{aligned} u_1 &= [13000, x_1], u_2 = [x_1, x_2], u_3 = [x_2, x_3], u_4 = [x_3, x_4], \\ &\quad \vdots, u_5 = [x_4, x_5], \quad u_6 = [x_5, x_6], u_7 = [x_6, 20000]. \end{aligned}$$

که در آن $x_1, x_2, x_3, x_4, x_5, x_6$ اعداد طبیعی بین ۱۳۰۰۰ و ۲۰۰۰۰ و $x_1 < x_2 < x_3 < x_4 < x_5 < x_6$ هستند. هدف ما تعیین مقادیر بینه $x_1, x_2, x_3, x_4, x_5, x_6$ یا بازه‌ها است. برای این منظور ابتدا به تشکیل ماتریس حافظه الگوریتم می‌پردازیم. با فرض $HMS=10$ ، ماتریس حافظه یک ماتریس 10×6 است. در واقع این ماتریس حاوی ده جواب (هارمونی) تصادفی از مقادیر $x_1, x_2, x_3, x_4, x_5, x_6$ است. ماتریس تصادفی نمونه برای این مسئله به صورت زیر است:

1. Universe of Discourse

$$HM = \begin{bmatrix} 13065 & 15125 & 16859 & 17525 & 18854 & 19553 \\ 14275 & 16155 & 18789 & 19115 & 19465 & 19879 \\ & & \vdots & & & \\ & & 13123 & 14654 & 15872 & 17123 & 17954 & 19683 \end{bmatrix}_{10 \times 6}$$

سپس مقدار RMSE هر ردیف ماتریس حافظه با توجه به قدمهای زیر محاسبه می‌شود. سپس با توجه به مراحل الگوریتم هارمونی، به ایجاد یک راه حل جدید یا هارمونی جدید بر طبق قواعد گفته شده می‌پردازیم. RMSE این راه حل جدید را محاسبه کرده و در صورتی که از بدترین عضو ماتریس حافظه بهتر باشد، جایگزین آن خواهد شد. این الگوریتم را برای تعداد تکرار معین اجرا کرده و بهترین راه حل حافظه به عنوان بهترین افزار و پیش‌بینی محاسبه خواهد شد. طبق قوانین الگوریتم هارمونی بعد از تولید راه حل جدید، طبق مراحل زیر به پیش‌بینی بر مبنای افزار تولید شده بر مجموعه U می‌پردازیم.

مرحله (۱) بعد از تولید افزار جدید از طریق الگوریتم هارمونی، مجموعه‌های فازی را با استفاده از بازه‌ها مشخص کرده و داده‌ها را فازی می‌کنیم. مجموعه‌های فازی را به صورت $A_1, A_2, A_3, A_4, A_5, \square_6, A_7$ و با استفاده از رابطه (۵) که نشان‌دهنده‌ی رابطه کیفی است تعریف می‌کنیم.

$$A = \sum_{i=1}^n \frac{\mu_A(u_i)}{u_i} = \frac{\mu_A(u_1)}{u_1} + \frac{\mu_A(u_2)}{u_2} + \dots + \frac{\mu_A(u_n)}{u_n} \quad (5)$$

به عنوان مثال مجموعه‌ی A_7 و \square_6 عبارتند از:

$$A_1 = \frac{1}{u_1} + 0.5/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 .$$

$$A_7 = 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0.5/u_6 + 1/u_7 .$$

این متغیرهای زمانی، به ترتیب $A_7, A_6, A_5, A_4, A_3, \square_2, A_1$ به معنی "بسیار کم"، "کم"، "اندکی کم"، "متوسط"، "اندکی زیاد"، "زیاد"، "بسیار زیاد" هستند.

مرحله (۲) در قدم بعدی روابط فازی را استخراج کرده و این روابط را بر اساس دست چپ روابط، گروه‌بندی می‌کنیم. این روابط را به صورت زیر در می‌آوریم:

$$A_m \rightarrow A_s, A_t, \dots \quad A_i \rightarrow A_u, A_v, \dots$$

مرحله (۳) در این مرحله به پیش‌بینی می‌پردازیم، این پیش‌بینی‌ها طبق روابط منطقی فازی بالا محاسبه می‌شود. برای مثال در دوره اول رابطه فازی $A_1 \rightarrow A_2$ است. بنابراین پیش‌بینی A_2 خواهد بود. یا در دوره پنجم رابطه فازی $A_5 \rightarrow A_3, A_4, A_5, A_5$ است. بنابراین پیش‌بینی A_3, A_4, A_5 خواهد بود.

مرحله (۴) در این مرحله به غیرفازی‌سازی مقادیر فازی مرحله قبل می‌پردازیم. برای این منظور اگر مقدار پیش‌بینی یک دوره به صورت $A_{j1}, A_{j2}, \dots, A_{jk}$ باشد؛ در این صورت ماتریس غیر فازی این پیش‌بینی برابر است با ماتریس نقاط میانی بازه‌های $M(t) = [m_{j1}, m_{j2}, \dots, m_{jk}]$ که به صورت $u_{j1}, u_{j2}, \dots, u_{jk}$ نمایش داده می‌شود. برای مثال ماتریس غیرفازی‌سازی رابطه منطقی فازی $A_5 \rightarrow A_3, A_4, A_5, A_5$ ، برابر با $M(t) = [m_3, m_4, m_5, m_5]$ که نقطه میانی بازه ۱ است.

مرحله (۵) در این مرحله به تخصیص اوزان می‌پردازیم. اگر فرض کنیم پیش‌بینی دوره‌ی j ام به صورت، $A_{j1}, A_{j2}, \dots, A_{jk}$ باشد و مقادیر اوزان w_1, w_2, \dots, w_k را به این پیش‌بینی نسبت داده باشیم؛ مجموع اوزان باید برابر واحد باشد. به علت این که دوره‌های اخیر از اهمیت بیشتری برخوردار است، وزن دوره‌های آخر بیشتر در نظر گرفته می‌شود و رابطه (۶) برقرار است.

$$W_1 \leq W_2 \leq \dots \leq W_k \quad (6)$$

برای سادگی می‌توان اوزان را از ۱ شروع و برای هر مقدار یک واحد به آن اضافه سپس این اوزان را استانداردسازی کرد (مجموع برابر واحد). بنابراین می‌توان اوزان را به صورت (7) بیان نمود:

$$W(t) = [w_1, w_2, \dots, w_k] = \left[\frac{1}{\sum_{h=1}^k h}, \frac{2}{\sum_{h=1}^k h}, \dots, \frac{k}{\sum_{h=1}^k h} \right] \quad (7)$$

مرحله (۶) مقدار پیش‌بینی نهایی در مدل فازی وزن‌دار برابر است با حاصل ضرب ماتریس غیرفازی شده در ترانهاده‌ی ماتریس اوزان. بنابراین مقدار پیش‌بینی نهایی به صورت معادله (8) است:

$$\mathbf{M(t)} \times \mathbf{W(t)^T} = [\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_k] \times [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k]^T \quad (8)$$

$$\begin{bmatrix} \frac{1}{10}, \frac{2}{10,3} \\ \frac{10,4}{10} \end{bmatrix}$$

برای پیش‌بینی $\mathbf{A_3, A_4, A_5, A_6}$ و اوزان داریم:

$$\text{final forecast}(t) = [\mathbf{m}_3, \mathbf{m}_4, \mathbf{m}_5, \mathbf{m}_6] \times [0.1, 0.2, 0.3, 0.4]^T \quad (9)$$

بعد از پیش‌بینی مقدار تمام دوره‌های مورد نظر، مقدار RMSE این افزار را با توجه به مقدار پیش‌بینی و مقدار واقعی موجود به دست می‌آوریم؛ مقدار RMSE افزار موجود را با بدترین افزار موجود در حافظه هارمونی مقایسه کرده و در صورتی که از آن بهتر باشد، جایگزین آن خواهد شد. بعد از این مرحله، دوباره با توجه به قوانین الگوریتم هارمونی، افزار جدید تولید شده و این عمل تا وقتی که شرط توقف الگوریتم برقرار شود انجام خواهد شد.

تحلیل تجربی

در این بخش مطالعه تجربی صورت گرفته در راستای فراهم ساختن پاسخ برای سؤال‌های مطرح شده در این پژوهش، ارایه می‌شود. برای پاسخ‌گویی به وجود حافظه بلندمدت در بازده و تلاطم سهام صنعت سیمان از آزمون‌های آماری وجود حافظه بلندمدت (آماره R/S تعديل شده و آزمون GPH) استفاده شد. از آن‌جا که هدف نهایی پژوهش تجربی ما، معرفی مدل‌هایی است که توانایی بهتری در تبیین فرآیند تولید داده‌ها^۱ (که ناشناخته است) داشته باشند و بتوانند پیش‌بینی دقیق‌تری از سری زمانی ارایه دهند، سؤال دوم این پژوهش به ارزیابی دقیقت مدل‌های مختلف در پیش‌بینی بازده شاخص سهام صنعت سیمان اختصاص داشت که در این راستا از مدل‌سازی و پیش‌بینی شاخص مورد بررسی با استفاده از مدل‌هایی که ویژگی حافظه بلندمدت را در نظر می‌گیرند، نظیر ARFIMA و FIGARCH و مدل-هایی که این ویژگی را در نظر نمی‌گیرند مانند ARMA و GARCH استفاده و نتایج حاصل با مدل فرآبتكاری ارایه شده مقایسه شده است.

1. Data Generating Process (DGP)

معرفی شاخص مورد مطالعه و ویژگی‌های آماری آن

در این پژوهش، از بازده شاخص قیمت صنعت سیمان در مدل‌سازی‌ها، برآوردها و آزمون‌ها استفاده می‌شود. بازه زمانی مورد پژوهش نیز برای داده‌های روزانه از ۱۳۷۷/۰۸/۰۷ تا ۱۳۸۸/۰۷/۳۱ در نظر گرفته شده است و از آنجایی که در شاخص قیمت فقط تغییرات قیمت لحظه شده است، از شاخص قیمت با لحاظ نمودن بازده نقدی استفاده شد. قبل از مدل‌سازی بازده باید ویژگی‌های آماری توزیع آن را بررسی کرد، بدین منظور ویژگی‌های آماری توزیع بازده شاخص صنعت سیمان در ذیل آورده شده است. همان‌طور که در جدول (۱)، مشاهده می‌شود میانگین بازده روزانه شاخص صنعت سیمان از آبان‌ماه ۱۳۷۷ تا پایان مهرماه ۱۳۸۸ برابر مقدار منفی ۰/۰۰۶۵۹۴ و انحراف معیار آن ۰/۰۰۰۶۵۹۴ بوده است.

جدول ۱. ویژگی‌های آماری توزیع بازده شاخص‌ها

کشیدگی	چولگی	انحراف معیار	میانگین	شاخص
۹۰/۷۱۶۰۴	۴/۸۳۳۶۶۵	۰/۰۰۶۵۹۴	-۰/۰۰۰۶۵۹۴	بازده روزانه شاخص صنعت سیمان

مقدار انحراف معیار در مقایسه با میانگین نشان می‌دهد، این متغیر در طول دوره مورد بررسی از تلاطم بالایی برخوردار نبوده است. این توزیع دارای ضریب چولگی ۴/۸ بوده که به معنای چولگی به راست است، همچنین کشیدگی آن ۹۰/۷ که خیلی بیشتر از کشیدگی تابع چگالی نرمال است. بنابراین منحنی آن دارای دمب دراز و پهن و قله بلند بوده که ویژگی متداول بازدهی قیمت سری‌های زمانی مالی است.

بورسی حافظه بلندمدت

برای بررسی حافظه بلندمدت در سری زمانی مورد مطالعه از آزمون GPH و آماره R/S استفاده شده است. در آزمون GPH و آماره R/S فرضیه صفر نبود حافظه بلندمدت و فرض مقابله وجود حافظه بلندمدت در سری زمانی است. بنابراین، چنانچه آماره آزمون اختلاف

معناداری از صفر نداشته باشد، فرض صفر یعنی نبود حافظه بلندمدت را نمی‌توان رد کرد. نتایج به کارگیری هر یک از دو آزمون گفته شده در جدول (۲) ارایه شده است.

جدول ۲. نتایج بررسی آزمون‌های حافظه بلندمدت

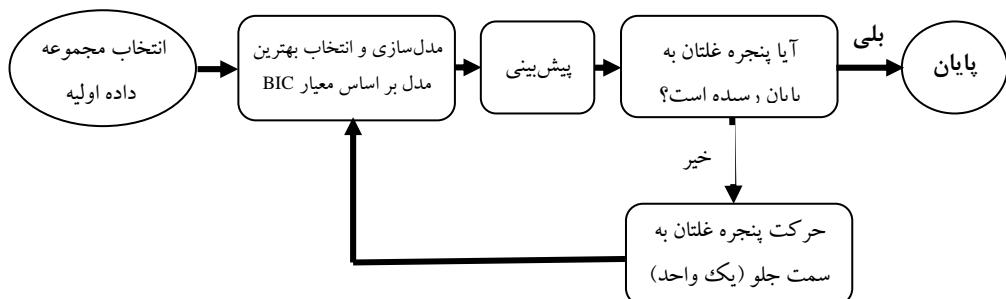
شناخت	تست حافظه بلندمدت			سطح معناداری	
	R/S	آماره GPH	آماره d	% ۹۵	% ۹۹
صنعت سیمان	۲/۳۸۹	** ۳/۳۶۵	۰/۳۲۴۷	*	**

بر اساس نتایج ارایه شده در جدول (۳)، وجود حافظه بلندمدت در بازده شاخص صنعت سیمان توسط هر دو آزمون در سطح اطمینان ۹۹٪ تأیید می‌شود. با توجه به مقدار مثبت و کوچک‌تر از ۰/۵ به دست آمده برای پارامتر حافظه بلندمدت (d) مشخص است که سری زمانی مورد مطالعه مانا است.

ارزیابی عملکرد مدل فراینتکاری ارایه شده

به منظور ارزیابی دقت پیش‌بینی مدل ارایه شده در این پژوهش از روش پنجره غلتان و معیار ریشه میانگین توان دوم خطاهای (RMSE) استفاده شده است. در گام اول پنجره غلتانی در نرم‌افزار S-PLUS برنامه‌نویسی شد که از ۲۲۰۰ داده اولیه از مجموع ۲۶۵۹ داده سری زمانی بازده شاخص صنعت سیمان استفاده می‌نماید. این پنجره غلتان با افزودن داده بعدی و حذف اولین داده حرکت کرده و فرآیند مدل‌سازی مجدد تکرار می‌شود و این کار تا آخرین مشاهده از ۲۶۵۹ داده پژوهش ادامه می‌یابد. پارامترهای مدل در هر مرحله برای ۴ مدل مورد مقایسه قرار گرفته با استفاده از روش باکس-جنکینز و معیار^۱ BIC تعیین شده‌اند. بر این اساس مدلی برتر شناخته می‌شود که آماره BIC کمتری داشته باشد. در هر مرحله از حرکت پنجره غلتان و پس از تعیین بهترین مدل برای داده‌های آن پنجره، پیش-بینی ۱-۵-۲۰-۶۰ و ۱۲۰-مرحله جلوتر بازده شاخص انجام شده است. فرآیند گفته شده را می‌توان به صورت الگوریتم ارائه شده در نمودار (۱) نمایش داد.

1. Bayesian information criterion



نمودار ۱. حرکت پنجره غلتان و پیش‌بینی بر اساس بهترین مدل در هر پنجره

الگوریتم بالا برای هر یک از مدل‌های ARMA، GARCH و ARFIMA نیز جداگانه انجام شده است. در نهایت بهمنظور ارزیابی دقیق هر یک از مدل‌ها در پیش‌بینی بازده شاخص کل، از معیار میانگین توان دوم خطاهای استفاده شده است. این معیار به صورت رابطه (۱۰) است.

$$RMSE = \sqrt{E[(\hat{r}_i - r_i)^2]} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (10)$$

که در آن e_i خطای پیش‌بینی یعنی اختلاف بازده پیش‌بینی شده از بازده تحقق یافته می‌باشد و به صورت $e_i = \hat{r}_i - r_i$ محاسبه شده است. گفتنی است، هنگامی که \hat{r}_i برآورد کننده نااریب پارامتر r_i نباشد، بهتر است که برای ارزیابی عملکرد مدل پیش‌بینی از شاخص ریشه میانگین توان دوم خطاهای (RMSE) استفاده کنیم. نتایج میانگین توان دوم خطاهای بازده پیش‌بینی شده در مقایسه با تحقق یافته برای مدل‌ها و دوره‌های زمانی مختلف در جدول (۳) آورده شده است.

جدول ۳. ارزیابی ریشه میانگین توان دوم خطاهای در مدل‌های مختلف پیش‌بینی

دوره زمانی پیش‌بینی	روشهای میانگین توان دوم خطاهای (RMSE)				
	مدل فرآیندکاری	ARMA	GARCH	ARFIMA	FIGARCH
-۱- گام جلوتر	۰/۰۰۴۶۷۴	۰/۰۰۵۰۸۵	۰/۰۰۵۳۳۰	۰/۰۰۵۲۲۷	۰/۰۰۵۲۶۲
-۵- گام جلوتر	۰/۰۰۳۸۹۴	۰/۰۰۵۵۱۰	۰/۰۰۵۵۲۶	۰/۰۰۵۵۰۱	۰/۰۰۵۴۹۲
-۲۰- گام جلوتر	۰/۰۰۰۴۶۳۹	۰/۰۰۵۸۱۴	۰/۰۰۵۷۹۱	۰/۰۰۸۳۲۵	۰/۰۰۵۷۹۰
-۶۰- گام جلوتر	۰/۰۰۴۲۸۶	۰/۰۰۵۹۳۳	۰/۰۰۶۰۹۸	۰/۰۰۶۲۳۶	۰/۰۰۵۸۸۹
-۱۲۰- گام جلوتر	۰/۰۰۳۹۳۵	۰/۰۰۵۹۴۲	۰/۰۰۷۴۸۵	۰/۰۰۸۵۷۳	۰/۰۰۵۷۷۸

مقایسه ریشه میانگین توان دوم خطای مدل‌های ARFIMA، GARCH، ARMA و FIGARCH با مدل فرابتکاری ارایه شده بیانگر آن است که این مدل در تمامی دوره‌های زمانی قادر است پیش‌بینی بهتری را ارایه نماید. مدل ARMA در پیش‌بینی یک روز جلوتر نتایج قابل رقابتی را با سایر مدل‌های اقتصادسنجی ارایه می‌نماید و همچنین پس از مدل فرابتکاری ارایه شده مدل FIGARCH از کمترین میزان خطای پیش‌بینی برخوردار است.

ارزیابی دقت مدل‌های پیش‌بینی

به منظور مقایسه آماری مدل‌های مختلفی که برای پیش‌بینی به کار گرفته شده‌اند از آزمون دیبولد-ماریانو^۱ (۱۹۹۵) استفاده می‌شود. این آزمون نشان می‌دهد که آیا تفاوت در دقت مدل‌های پیش‌بینی از لحاظ آماری معنادار است یا خیر. آماره DM به صورت زیر محاسبه می‌شود؛

اگر $\hat{\epsilon}_{t+h|t}^1$ و $\hat{\epsilon}_{t+h|t}^2$ خطای پیش‌بینی h مرحله جلوتر مدل‌های فرضی (۱) و (۲) باشند و N حداکثر تعداد مراحل در نظر گرفته شود. دقت پیش‌بینی به وسیله‌ی یکتابع زیان به شکل $L(\hat{\epsilon}_{t+h|t}^i) = (\hat{\epsilon}_{t+h|t}^i)^2$ یا قدر مطلق $L(\hat{\epsilon}_{t+h|t}^i)$ ، $i = 1, 2$ است در نظر گرفته می‌شود. برای رسیدن به اینکه کدام پیش‌بینی بهتر از دیگری است، باید تفاضل تابع زیان d_t ، به صورت رابطه (۱۱) محاسبه شود؛

$$d_t = L(\hat{\epsilon}_{t+h|t}^1) - L(\hat{\epsilon}_{t+h|t}^2) \quad (11)$$

فرضیه صفر و فرضیه مقابل برای محاسبه دقت پیش‌بینی به صورت؛

$$\begin{cases} H_0 \Rightarrow E(d_t) = 0 \\ H_1 \Rightarrow E(d_t) \neq 0 \end{cases}$$

است که آماره آزمون در رابطه (۱۲) آورده شده است.

$$S = \frac{\bar{d}}{[\widehat{\text{avar}}(\bar{d})]^{\frac{1}{2}}} = \frac{\bar{d}}{\left[\frac{\widehat{\text{LRV}}_d}{T} \right]^{\frac{1}{2}}} \quad (12)$$

1. Diebold and Mariano

در این آماره \bar{d} میانگین سری تفاضلی تابع خطای نمونه است و به صورت رابطه (۱۳) تعریف می‌شود.

$$LRV \bar{d} = \gamma_0 + 2 \sum_{j=1}^{\infty} \gamma_j, \gamma_j = \text{cov}(d_t, d_{t-j}) \quad \bar{d} = \frac{1}{N} \sum_{t=1}^N d_t \quad (13)$$

دیبولد و ماریانو نشان دادند، تحت فرض صفر مبتنی بر برابری دقت پیش‌بینی، آماره آزمون به طور مجانبی دارای توزیع نرمال استاندارد $S^A_N(\square, 1)$ است. بنابراین فرض صفر در سطح معناداری ۵ درصد در صورتی رد می‌شود که $|DM| > 1/96$ باشد. قرار گرفتن آماره DM در ناحیه بحرانی به معنای وجود تفاوت در دقت پیش‌بینی مدل‌های مورد مقایسه است. نتایج حاصل از محاسبه آماره (DM) بر روی پنج مدل مورد بررسی در این پژوهش در جدول (۴) آورده شده است.

جدول ۴. نتایج حاصل از آزمون دیبولد - ماریانو (DM-test)

بررسی مقادیر حاصل از آزمون دیبولد-ماریانو (DM-test) نشان‌دهنده آن بود که هیچ-یک از مقادیر آماره محاسبه شده در سطح معناداری ۵ درصد معنادار نبودند. این امر نشان-دهنده‌ی آن است که تفاوت در دقت هر یک از چهار مدل مختلف پیش‌بینی از لحاظ آماری اختلاف معناداری ندارند.

نتیجه‌گیری

با توجه به مطالب ارایه شده، آزمون‌های انجام شده و ارزیابی دقت مدل‌های پیش‌بینی نتایج زیر حاصل می‌شود.

نتایج آزمون GPH و آماره R/S وجود حافظه بلندمدت در سری زمانی بازده شاخص صنعت سیمان را تأیید نمود و با توجه به اینکه سری زمانی دارای ویژگی حافظه بلندمدت بود، اما روش برخورد با ریسک و بازده مورد انتظار غیرخطی بوده و از مدل‌های FIGARCH و ARFIMA استفاده شد.

در مدل‌سازی بازده شاخص قیمت سهام صنعت سیمان جهت پیش‌بینی مدلی جدید ارایه شد که از ترکیب روش جستجوی هارمونی و فازی وزن‌دار بود. همچنین برای بررسی دقت و کارایی مدل ارایه شده از چهار مدل استفاده شد؛ (۱) مدل ARMA که تلاطم‌ها را مستقل و دارای توزیع یکسان فرض کرده و حافظه بلندمدت را در نظر نمی‌گیرد؛ (۲) مدل GARCH که همبستگی تلاطم‌ها را در نظر گرفته، ولی وجود حافظه بلندمدت را در مدل لحاظ نمی‌کند؛ (۳) مدل ARIMA کسری یا ARFIMA که وجود حافظه بلندمدت را در سری زمانی بازده لحاظ کرده، ولی تلاطم‌های بازده را حول میانگین شرطی مستقل و دارای توزیع یکسان در نظر می‌گیرد؛ (۴) مدل FIGARCH که همبستگی و وجود حافظه-بلندمدت را در تلاطم‌های بازده حول میانگین شرطی لحاظ می‌کند. در مدل‌سازی بازده توسط پنج روش گفته شده، پنجره غلطانی به اندازه ۲۲۰۰ مشاهده در نظر گرفته و با حرکت پنجره غلطان به جلو، در هر مرحله بهترین پارامترهای مدل بر اساس معیار BIC تعیین شده است. این فرآیند برای هر یک از چهار مدل گفته شده جداگانه انجام شده

است. با حرکت پنجه غلطان به جلو و تعیین بهترین مدل‌ها، در هر مرحله بازده آینده شاخص برای دوره‌های روزانه، هفتگی، ماهانه، فصلی و شش‌ماهه پیش‌بینی شده و این عمل تا اتمام کلیه‌ی مشاهدات تکرار شده است. برای مقایسه عملکرد پیش‌بینی مدل ارایه شده با مدل‌های معروف شده از معیار ریشه میانگین توان دوم خطاهای (RMSE) استفاده شده است. نتایج این مطالعه نشان می‌دهد مدل فراباکاری ارایه شده در تمامی دوره‌های زمانی قادر است پیش‌بینی بهتری را ارایه نماید، همچنین پس از مدل فراباکاری ارایه شده مدل FIGARCH از کمترین میزان خطای پیش‌بینی بخوردار است و عملکرد بالاتری را ارایه می‌نماید.

منابع

۱. ابراهیمی سیدبابکی (۱۳۸۹). مدل‌سازی غیرخطی بازدهی و تلاطم در صنعت خودروسازی ایران، پایان‌نامه کارشناسی ارشد رشته علوم اقتصادی، دانشکده مدیریت و اقتصاد، دانشگاه صنعتی شریف.
۲. شعرائی سعید (۱۳۸۸). مدل‌سازی و پیش‌بینی بازده بورس اوراق بهادار تهران با استفاده از مدل‌های ARFIMA و FIGARCH، پایان‌نامه کارشناسی ارشد مدیریت مالی، دانشکده مدیریت و حسابداری دانشگاه شهرد بهشتی.
۳. مشیری سعید، فائزه فروتن (۱۳۸۳). آزمون آشوب و پیش‌بینی قیمت‌های نفت خام. فصلنامه پژوهش‌های اقتصادی ایران، شماره ۲۱، ۲۱. دانشگاه علامه طباطبایی.
4. Chen S.M (1996). Forecasting Enrollments Based on Fuzzy Time Series., Journal of Fuzzy Sets and Systems, Vol. 81, 3: 311-319.
5. Lee L.W, Wang L.H, Chen S.M (2007). Temperature Prediction and TAIFEX Forecasting Based on Fuzzy Logical Relationships and Genetic Algorithms, Expert Systems with Applications, 33: 539-550.
6. Lee L.W, Wang L.H, Chen S.M,(2008). Temperature Prediction and TAIFEX Forecasting Based on High-Order Fuzzy Logical Relationships and Genetic Simulated Annealing techniques., Expert Systems with Applications, 34: 328-336.

7. Park J.I, Lee D.J, Song C.K, Chun M.G (2010). TAIFEX and KOSPI 200 Forecasting Based on Two-Factors High-Order Fuzzy Time Series and Particle Swarm Optimization., *Expert Systems with Applications*, 37: 959-967.
8. Wong H.L, Tu Y.H, Wang C.C (2010). Application of Fuzzy Time Series Models for Forecasting the Amount of Taiwan Export, *Expert Systems with Applications*, Vol. 37: 1465-1470.
9. Geem Z W, KIM J H, Loganathan G V,(2001). A new heuristic optimization algorithm: harmony search, *Simulation*, 72: 60-68.
10. Geweke J, Porter-Hudak S (1983). The estimation and application of long memory time series models. *Journal of Time Series Analysis*, 12: 221-238.
11. Granger C, Ding Z (1996). Varieties of Long Memory Models. *Journal of Econometrics*, 73: 61-77.
12. hing-Hsue Cheng, Tai-Liang Chen, Hia Jong Teoh, Chen-Han Chiang (2008). Fuzzy time-series based on adaptive expectation model for TAIEX forecasting, *Journal of Expert Systems with Applications*, 34: 1126-1132.
13. Huarng K (2001). Heuristic Models of Fuzzy Time Series for Forecasting, *Journal of Fuzzy Sets Systems*, 123: 369-386.
14. Hui-Kuang Yu (2005). Weighted fuzzy time series models for TAIEX forecasting, *Journal of Physica*, 349: 609-624.
15. Hurst H. (1951). Long-term capacity of reservoirs. *Trans Amer Soc Civ Eng, Engng* 116: 770–808.
16. Lee L.W, Wang L.W, Chen S.M,(2006). Handling Forecasting Problems Based on Two-Factors High-Order time Series, *IEEE Transactions on Fuzzy Systems*, 14: 468-477.
17. Maheu J.M, T.H. McCurdy (2002). Nonlinear Features of Realized FX Volatility, *Review of Economics and Statistics*, 84: 668–681.
18. Ruey-Chyn Tsaur, Jia-Chi O Yang, Hsiao-Fan Wang (2005). Fuzzy relation analysis in fuzzy time series model, *Journal of Computers & Mathematics with Applications*, 49: 539-548.
19. Song Q, Chissom B.S (1993). Fuzzy Time Series and its Model, *Journal of Fuzzy Sets and Systems*, 54: 269-277.