

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

فرناز برزین 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 دکتری مهندسی صنایع، دانشگاه علم و صنعت، ایران
۳. دانشجوی دکتری 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 پدید آمدن 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 نظیر، $ARMA$ و $GARCH$ که ویژگی حافظه بلندمدت را در مدل‌سازی سری زمانی در نظر نمی‌گیرند و مدل‌هایی مثل $ARFIMA$ و $FIGARCH$ ، که این ویژگی را مدنظر قرار می‌دهند، با روش نوین فرآبستگی آرایه 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 خطاها ($RMSE$) در بازه‌های زمانی مختلف مورد مقایسه قرار می‌گیرد. نتایج حاصل نشان می‌دهند که روش فرآبستگی آرایه شده در تمامی بازه‌های زمانی نتیجه بهتری از مدل‌های متداول اقتصادسنجی آرایه می‌دهد.

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

JEL Classification: C15, C22, C53

مقدمه

هنگامی که مشاهدات گذشته با مشاهدات در آینده دور همبستگی دارند و رابطه آن‌ها غیرقابل چشم‌پوشی است سری زمانی مورد مطالعه دارای ویژگی حافظه بلندمدت است و تشخیص این الگو کاربردهای مهمی برای خرید و فروش‌های کوتاه‌مدت و همچنین استراتژی سرمایه‌گذاری بلندمدت دارد؛ زیرا تصمیمات سرمایه‌گذاری 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 می‌گردد و در دینامیک سری زمانی پارامتری را تولید می‌نماید که قابلیت پیش‌بینی دارد. از این پارامتر در ادبیات مالی با عنوان پارامتر حافظه‌ی بلندمدت (d) نام برده می‌شود [۱۱].

از آن‌جا که حافظه بلندمدت موجب وابستگی بازده دارایی با بازده‌های قبلی (دوره $t-k$ و t) می‌شود، نشان‌دهنده وجود پارامتری قابل پیش‌بینی در دینامیک سری زمانی است. وجود این ویژگی دلیلی بر رد شکل ضعیف فرضیه کارایی بازار است. مطابق فرضیه بازار کارا قیمت دارایی‌ها نباید با استفاده از داده‌های قیمت دوره‌های گذشته قابل پیش‌بینی باشد. یکی از مهم‌ترین مدل‌های غیرخطی که برای پیش‌بینی و تبیین رفتار تلاطم‌ها در بازارهای مالی استفاده می‌شود، مدل‌های GARCH است و بسته به اینکه به تنهایی مدل‌سازی سری زمانی بازدهی سهام صورت پذیرد یا اینکه تلاطم‌های آن نیز با لحاظ نمودن حافظه بلندمدت در نظر گرفته شود، روش تحلیلی مورد استفاده می‌تواند خانواده ARMA بوده یا به صورت FIGARCH تغییر یابد [۱][۲].

تمرکز اصلی این مقاله بر ارایه یک مدل فراابتکاری از ترکیب الگوریتم جستجوی هارمونی^۱ و سری‌های زمانی فازی وزن‌دار و مقایسه دقت پیش‌بینی آن با مدل‌های مختلف استوار است. در این راستا در فواصل زمانی مختلف مدل‌ها را مورد ارزیابی قرار داده و بهترین مدل برای پیش‌بینی انتخاب می‌شود. سؤالی که در این پژوهش طرح و به آن‌ها پاسخ داده می‌شود، می‌توان در قالب این پرسش بیان نمود که عملکرد مدل‌های مختلف در

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 مطلوب‌تری را به همراه دارند.

در این مقاله نیز ابتدا مروری بر پیشینه تجربی پژوهش‌هایی که به مدل‌سازی و مقایسه دقت پیش‌بینی مدل‌های مختلف پرداخته‌اند، صورت می‌گیرد. سپس پایه‌های ساخت مدل فراابتکاری پیشنهادی به تفصیل توضیح داده می‌شود. همچنین به تحلیل تجربی و مقایسه عملکرد مدل فراابتکاری ارایه شده و مدل‌های ARMA، GARCH، ARFIMA، 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.

پیشینه 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 ARMA، ARFIMA، GARCH و FIGARCH اشاره کرد. اما استفاده از مدل‌های فراابتکاری 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 چیسوم^۱ (۱۹۹۳) [۱۹] تئوری سری‌های زمانی فازی را مطرح ساختند. بر اساس این تئوری چن^۲ (۱۹۹۶) [۴] مدلی را برای پیش‌بینی پذیرش دانشجو در دانشگاه آلاباما 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 ارائه 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 می‌تواند 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 به‌طور مناسب بر روی داده‌ها برازش شوند. برای رسیدن به چنین هدفی هوارگ برای اولین بار از الگوریتم‌های فراابتکاری استفاده نمود [۱۳]. سائور 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 دقیق‌تر روند دراز مدت پرداخته و روشی را برای تشکیل ماتریس روابط فازی در این نوع روند ارائه 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 ارائه دادند که از آن برای پیش‌بینی سری‌های زمانی مربوط به TAIEEX 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 فراابتکاری ژنتیک و شبیه‌سازی تبرید مدل‌هایی برای پیش‌بینی درجه حرارت و شاخص بورس تایوان ارائه دادند [۵][۶]. چنگ^۵ و همکاران (۲۰۰۸) [۱۲]، با ارائه 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 مسایل پیش‌بینی فازی ارائه دهند. 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 ARMA و ARIMA انجام دادند و نشان دادند که در پیش‌بینی‌های کوتاه مدت مدل‌های فازی و در پیش‌بینی بلندمدت مدل‌های ARFIMA و FIGARCH از دقت 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 پرداختند 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 ارائه 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 پردازد، انجام نشده است و از این لحاظ توسعه نظری و به‌دنبال آن تحلیل تجربی انجام شده در این مقاله گامی ارزنده به‌شمار 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 بیانگر وجود یا نبود ریشه واحد نیز است. آزمون حافظه بلندمدت به روش آزمون GPH که توسط گوک، پورتر و هوداک^۱ (۱۹۸۳) [۱۰] ارائه شده است و آماره R/S تعدیل 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 r_t ، به ازای $t = 1, 2, \dots, T$ آماره R/S تعدیل شده به کار گرفته می‌شود. در این آزمون‌ها فرضیه صفر نبود حافظه بلندمدت و فرضیه مقابل 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 فراابتکاری ارائه شده

در راستای مدل‌سازی و پیش‌بینی شاخص قیمت بازدهی سهام صنعت سیمان از مدل‌های ARMA و GARCH به‌عنوان مدل‌های پرکاربرد اقتصادسنجی که قادر به در نظر گرفتن ویژگی حافظه بلندمدت نیستند، استفاده شده است. همچنین از مدل‌های ARFIMA و FIGARCH به‌عنوان مدل‌هایی که قادر به مدل‌سازی حافظه بلندمدت هستند، استفاده شده است. پایه‌های تئوریک و ساختار مدل فراابتکاری ارائه 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 چیسیم [۱۹]، تئوری سری‌های زمانی فازی را مطرح ساخته و در مقاله خود اصولی را مطرح نمودند که تمامی مدل‌های تعمیم داده شده بر مبنای این اصول هستند.

تعریف (۱) $Y(t) (t = \dots, 0, 1, 2, \dots)$ (مقادیر متغیر در لحظه‌ی t) را زیر مجموعه‌ای از اعداد حقیقی در نظر بگیرید و همچنین دامنه‌ی تغییرات متغیر توسط مجموعه‌های فازی $f_j(t)$ افزاز شده باشد، در چنین شرایط اگر $F(t)$ مجموعه‌ای از $f_1(t), f_2(t), \dots$ 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 $F(t) = F(t-1) \circ R(t-1, t)$ و "o" نشانگر عملگر max-min باشد و $F(t)$ و $F(t-1)$ هر کدام یک مجموعه‌ی فازی باشند، 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 رابطه 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 $F(t)$ توسط $F(t-1)$ به وجود آمده باشد و برای هر t داشته باشیم:

$F(t) = F(t-1).R(t-1, t)$ و $R(t-1, t)$ مستقل از t باشد، در نتیجه $F(t)$ یک سری زمانی مستقل از زمان خواهد بود و در غیر این صورت وابسته به زمان است.

الگوریتم جستجوی هارمونی

یکی از الگوریتم‌های فراابتکاری الگوریتم جستجوی هارمونی است که اولین بار در سال ۲۰۰۱ توسط گیم و همکاران ارائه شد و با توجه به نتایج به دست آمده از مقاله‌های ارائه شده و حل مسایل گوناگون، الگوریتمی کارا و سریع شناخته شده است [۹]. مانند سایر الگوریتم‌های فراابتکاری که بیشتر آن‌ها از طبیعت و محیط اطراف الهام گرفته و گسترده شده‌اند (مانند الگوریتم ژنتیک و کلونی مورچه‌ها)، الگوریتم جستجوی هارمونی هم با توجه به هنر موسیقی و اینکه چگونه حس لذت گوش دادن 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 مسئله ریاضی دارد. از یک طرف یک موسیقی‌دان در پی ایجاد و ساخت بهترین هارمونی ممکن است و آن مسئله هم در پی ایجاد و به دست 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 به طور 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 می-شوند. به عنوان مثال در این مطالعه به دنبال مینیم 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 HMCR و PAR 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. به‌طور معمول مقدار HMCR حدود ۰/۷ تا ۰/۹۵ 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 راه‌حل یا هارمونی تشکیل می‌شود. شکل کلی این ماتریس حافظه به صورت زیر است:

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

تعداد ردیف‌ها در این ماتریس حافظه به تعداد HMS^۵ است که هر ردیف به معنی یک راه حل یا جواب مسئله است. در این ماتریس تعداد 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 هیچ‌کدام از این هارمونی‌ها یا جواب‌ها بهترین هارمونی یا جواب ممکن نیست. با توجه به تابع برازش، مقدار برازش یا ارزش هر کدام از این راه‌حل‌ها را به دست می‌آوریم.

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

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

(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 i ام، 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 i ام از ماتریس حافظه و از ستون i ام انتخاب و در غیر این صورت یک مقدار تصادفی از فضای جستجو برای متغیر i ام 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 ی ماتریس، پارامتر دیگری به نام bw تعریف می شود که با توجه به رابطه (۳) مقدار متغیر جدید به دست می آید:

$$x_{new} = x_{old} + b_{range} \times \mathcal{E} \quad (۳)$$

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

(۴) به روز کردن ماتریس حافظه: به همین صورت تمام متغیرهای یک جواب یا هارمونی ایجاد و ارزش یا برآزش آن هارمونی با توجه به تابع برآزش 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 بهینه نزدیک خواهیم شد.

روش پیش‌بینی با استفاده از سری‌های فازی زمانی و الگوریتم جستجوی هارمونی مزیت استفاده از الگوریتم‌های فراابتکاری 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:

$$U = [D_{min} - D_1, D_{max} + D_2] \quad (۴)$$

در گام بعد به تولید ماتریس حافظه می‌پردازیم. برای مثال با فرض $D_{min} = 13055$ و $D_{max} = 19337$ مقدار $U = [13000, 20000]$ فرض می‌شود. مجموعه‌ی U به ۷ بازه افراز می‌شود:

$$u_1 = [13000, x_1], u_2 = [x_1, x_2], u_3 = [x_2, x_3], u_4 = [x_3, x_4], \\ u_5 = [x_4, x_5], u_6 = [x_5, x_6], u_7 = [x_6, 20000].$$

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 بهینه $x_1, x_2, x_3, x_4, x_5, x_6$ 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:

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

سپس مقدار RMSE هر ردیف ماتریس حافظه با توجه به قدم‌های زیر محاسبه می‌شود. سپس با توجه به مراحل الگوریتم هارمونی، به ایجاد یک راه‌حل جدید یا هارمونی جدید بر طبق قواعد گفته شده می‌پردازیم. RMSE این راه‌حل 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 راه‌حل حافظه به‌عنوان بهترین افزایش و پیش‌بینی محاسبه خواهد شد. طبق قوانین الگوریتم هارمونی بعد از تولید راه‌حل جدید، طبق مراحل زیر به پیش‌بینی بر مبنای افزایش تولید شده بر مجموعه U می‌پردازیم.

مرحله (۱) بعد از تولید افزایش جدید از طریق الگوریتم هارمونی، مجموعه‌های فازی را با استفاده از بازه‌ها مشخص کرده و داده‌ها را فازی می‌کنیم. مجموعه‌های فازی را به صورت $A_1, A_2, A_3, A_4, A_5, A_6, A_7$ و با استفاده از رابطه (۵) که نشان‌دهنده‌ی رابطه کیفی است تعریف می‌کنیم.

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

به‌عنوان مثال مجموعه‌ی A_1 و A_7 عبارتند از:

$$A_1 = 1/u_1 + 0.5/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7$$

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

این متغیرهای زمانی، به ترتیب $A_1, A_2, A_3, A_4, A_5, A_6, A_7$ به معنی "بسیار کم"، "کم"، "اندکی کم"، "متوسط"، "اندکی زیاد"، "زیاد"، "زیاد"، "بسیار زیاد" هستند.

مرحله (۲) در قدم بعدی روابط فازی را استخراج کرده و این روابط را بر اساس دست‌چپ روابط، گروه‌بندی می‌کنیم. این روابط را به‌صورت زیر در می‌آوریم:

$$A_m \rightarrow A_5, A_2, \dots \quad A_i \rightarrow A_7, A_1, \dots$$

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 $A_5 \rightarrow A_3, A_4, A_5$ 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 $u_{j1}, u_{j2}, \dots, u_{jk}$ که به صورت $M(t) = [m_{j1}, m_{j2}, \dots, m_{jk}]$ نمایش داده می‌شود. برای مثال ماتریس غیرفازی‌سازی رابطه منطقی فازی $A_5 \rightarrow A_3, A_4, A_5$ ، برابر با $M(t) = [m_3, m_4, m_5, m_5]$ که m_i نقطه میانی بازه i ام است.

مرحله ۵) در این مرحله به تخصیص اوزان می‌پردازیم. اگر فرض کنیم پیش‌بینی دوره i ام به صورت $A_{i1}, A_{i2}, \dots, A_{ik}$ 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 (۷) 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 (۸) است:

$$M(t) \times W(t)^T = [m_1, m_2, \dots, m_k] \times [\hat{w}_1, \hat{w}_2, \dots, \hat{w}_k]^T \quad (8)$$

برای پیش‌بینی A_3, A_4, A_5, A_5 و اوزان $\begin{bmatrix} 1 & 2 \\ 10, 10, 3 \\ 10, 4 \\ 10 \end{bmatrix}$ داریم:

$$\text{final forecast}(t) = [m_3, m_4, m_5, m_5] \times [0.1, 0.2, 0.3, 0.4]^T \quad (9)$$

بعد از پیش‌بینی مقدار تمام دوره‌های مورد نظر، مقدار RMSE این افراز را با توجه به مقدار پیش‌بینی و مقدار واقعی موجود به دست می‌آوریم؛ مقدار RMSE افراز موجود را با بدترین افراز 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، افراز 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 تعدیل 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 سری‌زمانی ارایه دهند، سؤال دوم این پژوهش به ارزیابی دقت 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 مدل‌هایی که این ویژگی را در نظر نمی‌گیرند مانند ARMA و GARCH استفاده و نتایج حاصل با مدل فراابتکاری 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 الی ۱۳۸۸/۰۷/۳۱ در نظر گرفته شده است و از آنجایی که در شاخص قیمت فقط تغییرات قیمت لحاظ 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 ۰/۰۰۰۱۶۹ و انحراف معیار آن ۰/۰۰۶۵۹۴ بوده است.

جدول ۱. ویژگی‌های آماری توزیع بازده شاخص‌ها

کشیدگی	چولگی	انحراف معیار	میانگین	شاخص
۹۰/۷۱۶۰۴	۴/۸۳۳۶۶۵	۰/۰۰۶۵۹۴	-۰/۰۰۰۱۶۹	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.

بررسی 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 مقابل 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

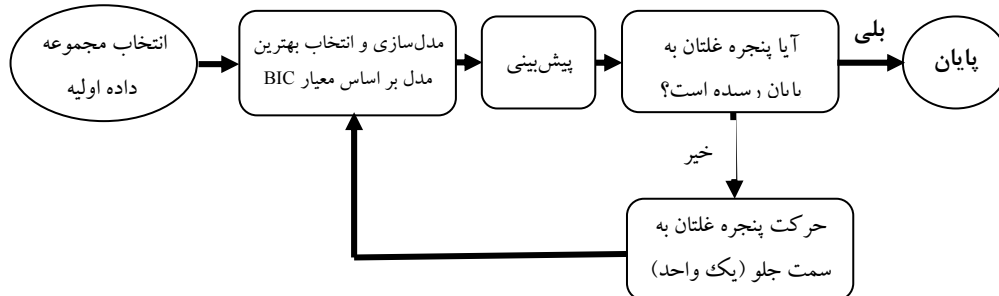
تست حافظه بلندمدت روش‌های GPH تست و آماره R/S			سطح معناداری		
شاخص	آماره R/S	آماره GPH	d	%۹۵	%۹۹
صنعت سیمان	۲/۳۸۹	** ۳/۳۶۵	۰/۳۲۴۷	*	**

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 فراابتکاری ارایه شده

به منظور ارزیابی دقت پیش‌بینی مدل ارایه شده در این پژوهش از روش پنجره غلتان و معیار ریشه میانگین توان دوم خطاها (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 مجدداً 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 BIC^۱ 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 پیش بینی بر اساس بهترین مدل در هر پنجره

الگوریتم بالا برای هر یک از مدل های ARMA، GARCH، ARFIMA و FIGARCH نیز جداگانه انجام شده است. در نهایت به منظور ارزیابی دقت هر یک از مدل ها در پیش بینی بازده شاخص کل، از معیار میانگین توان دوم خطاها 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 پیش بینی یعنی اختلاف بازده پیش بینی شده از بازده تحقق یافته می باشد و به صورت $e_i = \hat{r}_i - r_i$ محاسبه شده است. گفتنی است، هنگامی که \hat{r}_i برآوردکننده ناریب پارامتر r_i نباشد، بهتر است که برای ارزیابی عملکرد مدل پیش بینی از شاخص ریشه میانگین توان دوم خطاها (RMSE) استفاده کنیم. نتایج میانگین توان دوم خطاهای بازده پیش بینی شده در مقایسه با تحقق یافته برای مدل ها و دوره های زمانی مختلف در جدول (۳) آورده شده است.

جدول ۳. ارزیابی ریشه میانگین توان دوم خطاها در مدل های مختلف پیش بینی

دوره زمانی پیش بینی	ریشه میانگین توان دوم خطا (RMSE)				
	مدل فراابتکاری	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	۰/۰۰۴۶۳۹	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 ARMA، GARCH، ARFIMA و FIGARCH با مدل فراابتکاری 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 فراابتکاری 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 $\hat{\varepsilon}_{t+h|t}^1$ و $\hat{\varepsilon}_{t+h|t}^2$ خطای پیش‌بینی h مرحله جلوتر مدل‌های فرضی (۱) و (۲) باشند و N حداکثر تعداد مراحل در نظر گرفته شود. دقت پیش‌بینی به وسیله‌ی یک تابع زیان به شکل $L(\hat{\varepsilon}_{t+h|t}^i), i=1,2$ که به صورت توان دوم $L(\hat{\varepsilon}_{t+h|t}^i) = (\hat{\varepsilon}_{t+h|t}^i)^2$ یا قدرمطلق $L(\hat{\varepsilon}_{t+h|t}^i) = |\hat{\varepsilon}_{t+h|t}^i|$ 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؛

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

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.

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

در این آماره \bar{d} میانگین سری تفاضلی تابع خطا در 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 به‌طور مجانبی دارای توزیع نرمال استاندارد $SAN(\square, 1)$ 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)

		مدل فرابینکاری					ARMA					ARFIMA					GARCH					FIGARCH				
		۱	۵	۲۰	۶۰	۱۲۰	۱	۵	۲۰	۶۰	۱۲۰	۱	۵	۲۰	۶۰	۱۲۰	۱	۵	۲۰	۶۰	۱۲۰	۱	۵	۲۰	۶۰	۱۲۰
مدل فرابینکاری	کام ۱						۰.۸۵					-۰.۴					-۰.۵					-۰.۳				
	کام ۵							۰.۹					۰.۳					۰.۴					۰.۲			
	کام ۲۰								-۰.۱۷					۰.۱۴					-۰.۸					۰.۳		
	کام ۶۰									۰.۱۳					۰.۱۶					-۰.۱۴					-۰.۴	
	کام ۱۲۰										۰.۴					۰.۱۱					۰.۱۲					۰.۱۳
ARMA	کام ۱	۰.۸۵															-۰.۳									
	کام ۵		۰.۹										-۰.۱۱					-۰.۲					۰.۱۹			
	کام ۲۰			-۰.۱۷										-۰.۲۱					۰.۳۳					-۰.۱۲		
	کام ۶۰				۰.۱۳										-۰.۱۹					۰.۲					-۰.۱۷	
	کام ۱۲۰					۰.۴										-۰.۱۶					۰.۱۷					-۰.۱۱
ARFIMA	کام ۱	-۰.۴					-۰.۳															۰.۱۹				۰.۷
	کام ۵		۰.۳					-۰.۱۱										۰.۱۲					۰.۱۲			۰.۴
	کام ۲۰			-۰.۱۴					-۰.۲۱										-۰.۱۴					۰.۸		
	کام ۶۰				۰.۱۶					-۰.۱۹										-۰.۱۸					۰.۳۱	
	کام ۱۲۰					۰.۱۱					-۰.۱۶										-۰.۲۱					۰.۱۴
GARCH	کام ۱	-۰.۵					-۰.۷					۰.۱۹														-۰.۱۷
	کام ۵		۰.۴					-۰.۲					۰.۱۲													۰.۲
	کام ۲۰			-۰.۸					۰.۳۳					-۰.۱۴												-۰.۱۴
	کام ۶۰				۰.۱۴					۰.۲					-۰.۱۸										۰.۱۷	
	کام ۱۲۰					۰.۱۲					۰.۱۷					-۰.۲۱										۰.۲۱
FIGARCH	کام ۱	-۰.۳					۰.۲					۰.۷					-۰.۱۷									
	کام ۵		۰.۲					۰.۱۹					۰.۴					۰.۲								
	کام ۲۰			-۰.۲					-۰.۱۲					۰.۹					-۰.۱۴							
	کام ۶۰				-۰.۴					-۰.۱۷					۰.۳۱					-۰.۱۷						
	کام ۱۲۰					۰.۱۳					-۰.۱۱					۰.۱۴					-۰.۲۱					

بررسی مقادیر حاصل از آزمون دیبولد- ماریانو (DM-test) نشان دهنده 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 چهارمدل مختلف پیش‌بینی از لحاظ آماری اختلاف معناداری ندارند.

نتیجه‌گیری

با توجه به مطالب ارائه 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 ARFIMA و FIGARCH استفاده شد.

در مدل‌سازی بازده شاخص قیمت سهام صنعت سیمان جهت پیش‌بینی مدلی جدید ارائه شد که از ترکیب روش جستجوی هارمونی و فازی وزن‌دار بود. همچنین برای بررسی دقت و کارایی مدل ارائه 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 پنجره 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 کلیه مشاهدات تکرار شده است. برای مقایسه عملکرد پیش‌بینی مدل ارایه شده با مدل‌های معرفی شده از معیار ریشه میانگین توان دوم خطاها (RMSE) استفاده شده است. نتایج این مطالعه نشان می‌دهد مدل فراابتکاری ارایه شده در تمامی دوره‌های زمانی قادر است پیش‌بینی بهتری را ارایه نماید، همچنین پس از مدل فراابتکاری ارایه شده مدل FIGARCH از کمترین میزان خطای پیش‌بینی برخوردار است و عملکرد بالاتری را ارایه می‌نماید.

منابع

۱. ابراهیمی سیدبابک (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 شهید بهشتی.
۳. مشیری سعید، فائزه فروتن (۱۳۸۳). آزمون آشوب و پیش‌بینی قیمت‌های نفت خام. فصلنامه پژوهش‌های اقتصادی ایران، شماره ۲۱. دانشگاه علامه طباطبائی.
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 TAIEX 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 TAIEX 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). TAIEX 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.