



فصلنامه علمی پژوهشی دانش سرمایه‌گذاری
سال نهم / شماره سی‌وچهارم / تابستان ۱۳۹۹

طراحی مدلی جهت پیش‌بینی بازده شاخص بورس (با تأکید بر مدل‌های ترکیبی شبکه عصبی و مدل‌های حافظه بلندمدت)

رضا نجارزاده

دانشیار گروه علوم اقتصادی دانشگاه تربیت مدرس؛ تهران، ایران.
najarzar@modares.ac.ir

مهدی ذوالفقاری

استادیار گروه علوم اقتصادی دانشگاه تربیت مدرس؛ تهران، ایران. (نویسنده مسئول)
m.zolfaghari@modares.ac.ir

صمد غلامی

دانشجوی کارشناسی ارشد گروه علوم اقتصادی دانشگاه تربیت مدرس؛ تهران، ایران.
samgun118@gmail.com

تاریخ دریافت: ۹۷/۰۷/۲۵ تاریخ پذیرش: ۹۷/۰۹/۱۹

چکیده

این پژوهش به معرفی مدل‌هایی از ترکیب خانواده GARCH و شبکه عصبی مصنوعی، جهت پیش‌بینی بازدهی روزانه شاخص بورس اوراق بهادار تهران طی فاصله زمانی ۱۳۹۶-۱۳۸۷ می‌پردازد. وجود ویژگی حافظه بلندمدت در واریانس شرطی بازدهی شاخص کل بورس موجب شده تا علاوه بر مدل‌های دارای حافظه کوتاه‌مدت GARCH و EGARCH در این پژوهش از مدل‌های FIGARCH و FIEGARCH که دارای ویژگی حافظه بلندمدت هستند؛ استفاده گردد. علاوه بر بکارگیری مدل‌های حافظه کوتاه‌مدت، با توجه به کارایی بهتر مدل‌های ترکیبی (در مقایسه با مدل‌های فردی) در پیش‌بینی داده‌های مالی، در این مطالعه، تمامی مدل‌های خانواده GARCH (اعم از کوتاه‌مدت و بلندمدت) با شبکه عصبی مصنوعی ترکیب و با استفاده از مدل‌های ترکیبی حاصل‌شده، بازده شاخص بورس برای ۱۰ روز آینده به صورت گام‌به‌گام پیش‌بینی و دقت آن براساس معیارهای ارزیابی مورد بررسی قرار گرفت. یافته‌های تحقیق نشان داد که مدل ترکیبی FIEGARCH- شبکه عصبی با توزیع تی- استیودنت در پیش‌بینی بازده شاخص کل سهام کارآمدتر و دارای خطای پیش‌بینی کمتری نسبت به سایر مدل‌های رقیب است.

واژه‌های کلیدی: بازار سهام، پیش‌بینی، خانواده GARCH، شبکه عصبی، مدل ترکیبی

۱- مقدمه

سرمایه‌گذاری عبارت از انتخاب دارایی‌هایی برای نگهداری و کسب عایدی بیشتر به‌منظور کسب سود و رفاه اقتصادی بیشتر در آینده است. با توجه به منابع محدود سرمایه‌گذاری در کشور، همواره اقتصاددانان و متخصصان امور مالی در پی راه‌های استفاده مطلوب از منابع اقتصادی برای در اختیار گذاشتن سرمایه‌گذاران هستند (کریمی و همکاران، ۱۳۹۲). در این بین، بازار سهام نقش اساسی در تخصیص منابع سرمایه‌ای به بخش‌های مولد از طریق جذب منابع خرد و سرگردان را دارد. ساختار و چارچوب شفاف بازار سهام در قیمت‌گذاری و انتشار اطلاعات مربوط به ارزش مالی بنگاه‌های اقتصادی، باعث شناسایی این بازارها به‌عنوان نماینده وضعیت بخش واقعی اقتصاد شده است. از این‌رو مشخصه‌ی توانایی بازار سهام در انعکاس سریع و دقیق تمامی اطلاعات موجود، همواره مورد توجه تحلیلگران مالی، قانون‌گذاران و اقتصاددانان بوده است. علاوه بر این، یکی از راه‌های مقابله با ریسک نوسانات قیمتی، ورود به معاملات قراردادهای مشتقه مالی^۱ است که در بورس‌های بسیاری از کشورهای دیگر بر روی دارایی‌هایی نظیر سهام، ارز، کالا و شاخص کل سهام انجام می‌پذیرد. در بازارهای مالی ایران نیز بازار مشتقه برای سهام، طلا و کالا وجود دارد و اخیراً قوانین مربوط به راه‌اندازی بازار مشتقه شاخص کل بورس (تحت عنوان شاخص سبد سهام) در دستور کار سازمان بورس است. بنابراین تغییر در نماگرهای اصلی بازار سهام (نظیر شاخص کل بازار یا شاخص صنایع) مورد توجه سرمایه‌گذاران (داخلی و خارجی)، سیاست‌گذاران و برنامه‌ریزان و مراکز دانشگاهی شده است. در این راستا طیف گسترده‌ای از مطالعات کاربردی و مدل‌های اقتصادسنجی به پردازش رفتار و پیش‌بینی نوسانات این نماگرها منجر شده است. اهمیت پیش‌بینی نوسانات شاخص‌های قیمت در بازارهای سرمایه از جنبه مدیریت ریسک برای بسیاری از سهامداران بازار سرمایه باهدف بهینه‌سازی پرتفوی دارایی‌های مالی مهم است. از سوی دیگر یکی از راه‌های شناسایی و اندازه‌گیری ریسک در بازارهای مالی برای مقامات ناظر و قانون‌گذار، رصد و پیش‌بینی نوسانات قیمت سهام و شاخص‌های قیمت بازاری است (مارکویچ^۲، ۱۹۵۲). در تئوری‌های اقتصادسنجی برای مدل‌سازی نوسانات بازده به‌طور معمول از مدل‌های ناهمسانی واریانس شرطی خود رگرسیو ARCH^۳ و شکل تعمیم یافته آن GARCH^۴ و خانواده‌های مرتبط با آن نظیر EGARCH^۵ استفاده می‌شود که این مدل‌ها از پایه‌های تئوریک مالی و اقتصادی برخوردارند. یکی از ویژگی‌هایی که امکان دارد در بازارهای مالی وجود داشته باشد وجود حافظه بلندمدت است، به این معنی که در صورت نامانا بودن سری زمانی، اثر شوک‌های خارجی بر نوسانات آن سری دائمی خواهد بود. بنابراین جهت رفع این مشکل و جلوگیری از تفاضل‌گیری^۶ به جای استفاده از مدل‌های مرسوم خانواده GARCH از مدل‌های انباشته کسری^۷ آن یعنی FIGARCH^۸ و FIEGARCH^۹ که از انعطاف بالایی در توصیف نوسانات سری‌های زمانی برخوردار هستند؛ استفاده می‌شود. با مروری بر مطالعات صورت گرفته در حوزه پیش‌بینی قیمت سهام، بسیاری از تحقیقات مالی در سال‌های اخیر بر این مسئله متمرکز بوده است که مدل‌های سنتی خطی و غیرخطی را برای یافتن برآوردها و پیش‌بینی‌های دقیق‌تر، با مدل‌های هوش مصنوعی (نظیر شبکه عصبی) ترکیب کنند (سعیدی و محمدی، ۱۳۹۰). بنابراین، بهره‌گیری از این پایه‌های

نظری به همراه تلفیق آن با مدل های ناپارامتری همانند شبکه های عصبی می تواند به دقت سیستم پیش بینی کننده بیفزاید.

درسایر مطالعات انجام شده در این حوزه با در نظر گرفتن مدل های مرسوم خانواده GARCH و ترکیب آن با شبکه عصبی مصنوعی، سعی در پیش بینی نوسانات شاخص های مورد مطالعه شده است. این در حالی است که عدم لحاظ حافظه بلندمدت در مدل های مورد بررسی باعث کاهش توانایی مدل ها در پیش بینی سری های زمانی می گردد. با توجه به این مهم، در مطالعه حاضر سعی بر آن شده که در مدل های ترکیبی علاوه بر مدل های حافظه کوتاه مدت از مدلی که نشان دهنده حافظه بلندمدت هستند استفاده گردد و کاستی یافته های قبلی در این حوزه را بکاهد و دقت مدل ها را در پیش بینی نوسانات افزایش دهد.

بنابراین نوآوری های مقاله مذکور به ترتیب زیر می باشد

- توسعه مدل های بلندمدت حافظه FIGARCH و FIEGARCH
- ارایه مدل ترکیبی خانواده GARCH-شبکه عصبی
- لحاظ متغیرهای کنترلی قیمت نفت و ارز در مدل ترکیبی

با توجه به مباحث بالا می توان بیان داشت که هدف اصلی تحقیق حاضر ارایه مدلی نوین جهت بهبود قدرت پیش بینی مدل های سری زمانی مالی است. در واقع با اضافه کردن مدل های حافظه بلندمدت به مدل های ترکیبی پیشین که محور اصلی پژوهش حاضر می باشد، گام روبه جلویی در حوزه ادبیات پیش بینی داده های سری زمانی می توان برداشت.

در این مقاله بخش دوم به پیشینه تحقیق اختصاص یافته و در بخش سوم، مبانی نظری مدل های خانواده GARCH، شبکه های عصبی و مدل تلفیقی ارایه شده است. در بخش چهارم به مدل سازی و تخمین مدل های مذکور با استفاده از بازده روزانه شاخص بورس تهران^{۱۱} برای دوره ۱۳۸۷/۹/۲۳ الی ۱۳۹۶/۱۰/۲۵ پرداخته و مدل های مذکور در بازه زمانی یک گام تا ده گام به جلو پیش بینی شدند. قابل ذکر است در این مدل ها از دو متغیر قیمت جهانی نفت و نرخ ارز به عنوان متغیرهای کنترلی استفاده شده است. سپس با به کارگیری معیارهای سنجش به ارزیابی قدرت پیش بینی مدل های فوق پرداخته و در بخش پنجم نتایج ارائه شده است.

۲- مروری بر پیشینه پژوهش

با توجه به اهمیت نوسانات داده های مالی در مدیریت ریسک و بهینه سازی پرتفو، در سالیان گذشته طیف گسترده ای از مطالعات در این زمینه انجام یافته است. با توجه به موجود بودن این مطالعات در پیشینه تحقیق سایر مقالات داخلی، در این بخش صرفاً به بررسی مطالعات صورت گرفته با استفاده از مدل های ترکیبی شبکه عصبی و خانواده GARCH در پیش بینی نوسانات بازدهی دارایی های مالی پرداخته می شود.

در مطالعات خارجی، کریستجان پولر و میناتو^{۱۱} (۲۰۱۸) در مطالعه ای به اندازه گیری نوسانات قیمت بیت کوین^{۱۲} با استفاده از مدل ترکیبی GARCH-ANN از ۱۳ دسامبر ۲۰۱۱ تا ۲۶ آگوست ۲۰۱۷ برای سه دوره

۱۰،۲۲،۴۴ روزه پیش‌بینی کردند. در این تحقیق مدل ترکیبی در مقایسه با مدل‌های فردی و رقیب، دقت پیش‌بینی نوسان قیمت را به میزان قابل توجهی افزایش داد.

صدیق و همکاران^{۱۳} (۲۰۱۸) در مطالعه‌ای به جهت رسیدن به مدلی برای پیش‌بینی نوسان میزان سرمایه‌گذاری و رشد بودجه شرکت‌های مدیریت دارایی در پاکستان برای یک دوره پنج‌ماهه پرداخته و مدل ترکیبی GARCH-ANN را که دارای خطای پیش‌بینی کمتری نسبت به سایر مدل‌ها بود را پیشنهاد می‌نمایند. کریستجان پولر وهراندز^{۱۴} (۲۰۱۷) با استفاده از داده‌های روزانه سه فلز طلا، مس و آلومینیوم طی دوره ۷ سپتامبر ۲۰۰۹ تا ۲۰ می ۲۰۱۴ و با استفاده از متغیرهای کنترلی نرخ دلار، یوان، یورو، قیمت نفت و شاخص‌های سهام چین، هند، آمریکا به پیش‌بینی نوسان شاخص این سه فلز با مدل GARCH پرداخته و سپس این مدل را به‌عنوان ورودی شبکه عصبی به کار بردند. نتایج حاصله نشان داد که مدل ترکیبی قدرت پیش‌بینی نوسان خارج از نمونه این سه فلز را افزایش می‌دهد. در نهایت برای پیش‌بینی این نوسانات مدل GARCH-ANN پیشنهاد شد.

فاتیما^{۱۵} (۲۰۱۷) با استفاده از مدل‌های خانواده GARCH (EGARCH, A-GARCH) به بررسی نوسانات شاخص بورس بمبئی و کراچی از تاریخ ۱ ژانویه ۲۰۱۰ تا ۱۵ ژانویه ۲۰۱۶ پرداختند و سپس نتایج حاصله را با شبکه عصبی مصنوعی ترکیب کرده و با استفاده از این دو مدل به پیش‌بینی نوسانات این دو شاخص طی مدت ۱۵ روز پرداختند. سپس میزان خطای مدل‌های ترکیبی را با استفاده از شاخص مجذور مربع خطاها^{۱۶} RMSE مقایسه نمودند و به این نتیجه دست یافتند که مدل ترکیبی AGARCH-ANN دارای خطای پیش‌بینی کمتری نسبت به مدل‌های رقیب است.

لحمیری^{۱۸} (۲۰۱۷) با استفاده از مدل‌های ترکیبی GARCH-ANN و EGARCH-ANN با سه توزیع نرمال t ، student و GED^{۱۹} و با استفاده از داده‌های روزانه دلار کانادا و یورو از ۴ ژون ۲۰۱۰ تا ۶ دسامبر ۲۰۱۵ به پیش‌بینی نوسان داده‌ها برای مدت ۲۰ روز پرداخته و سپس با استفاده از دو شاخص قدر مطلق میانگین خطا MAE^{۲۰} و مربع میانگین خطا MSE^{۲۱} نتایج را مورد مقایسه قرار دادند و به این نتیجه دست یافتند که مدل ترکیبی EGARCH-ANN با توزیع GED توانایی بهتری در پیش‌بینی نوسان دلار کانادا و یورو دارد.

لو و همکاران^{۲۲} (۲۰۱۶) در مطالعه‌ای به مقایسه عملکرد پیش‌بینی مدل‌های ترکیبی شبکه عصبی و GARCH با مدل‌های خانواده GARCH (EGARCH) به پیش‌بینی نوسان بازدهی سهم انرژی چین طی دوره ۳۱ دسامبر ۲۰۱۳ تا ۱۰ مارس ۲۰۱۶ پرداخته و به این نتیجه رسیدند که مدل‌های ترکیبی EGARCH-ANN دارای خطای پیش‌بینی کمتر و قدرت پیش‌بینی بالاتری هستند.

لاهمری و بوکدوم^{۲۳} (۲۰۱۵) در مطالعه‌ای به بررسی نوسان بازدهی شاخص سهام S&P 500 با استفاده از مدل شبکه ترکیبی شبکه عصبی مصنوعی با الگوریتم پس انتشار خطا^{۲۴} BP و خانواده GARCH شامل EGARCH با دو توزیع GED و t برای دوره ۲۸ فوریه ۲۰۱۱ تا ۱۱ مارس همان سال پرداخته و نتایج را با استفاده از شاخص‌های مجذور مربع خطا RMSE و قدر مطلق میانگین خطا MAE مورد بررسی قرار

دادند. یافته‌های تحقیق نشان داد که مدل ترکیبی EGARCH-BP دارای خطای پیش‌بینی کمتر نسبت به سایر مدل‌های فردی است.

منفرد و انکه^{۲۵} (۲۰۱۴) در مطالعه‌ای بر روی بازار سهام آمریکا، به بررسی بازده سهام نزدیک از ۳ ژوئیه ۱۹۹۸ تا ۱۲ اکتبر ۲۰۱۲ با استفاده از مدل‌های ترکیبی GJR-GARCH^{۲۶} به همراه شبکه‌های عصبی شعاع مدار RBF^{۲۷} و پیش‌بینی آن برای مدت ۴۴ روز آتی پرداختند. یافته‌های تحقیق نشان داد که مدل ترکیبی GJR-GARCH-RBF دارای خطای کمتری نسبت به بقیه مدل‌ها در پیش‌بینی نوسان سهام است.

کریستجان پولر و دیگران^{۲۸} (۲۰۱۳) در مطالعه‌ای به پیش‌بینی بازده سهام کشورهای آمریکای لاتین شامل مکزیک، برزیل و شیلی طی سال‌های ۲۰۰۰-۲۰۱۱ با استفاده از شبکه عصبی و GARCH پرداخته و با مقایسه نتایج به این نتیجه رسیدند که فرآیند شبکه عصبی در پیش‌بینی، توانایی بهبود مدل GARCH را دارد.

انوار ومیکامی^{۲۹} (۲۰۱۱) به بررسی بازده سپرده بانک اسلام آباد طی دوره جون ۲۰۰۰ تا آوریل ۲۰۱۰ و دلار آمریکا به عنوان متغیر کنترلی و با استفاده از مدل GARCH و مدل ترکیبی GARCH-ANN پرداخته و سپس آن را برای یک دوره ۷ روزه پیش‌بینی و با استفاده از شاخص قدر مطلق میانگین خطا MAE و مربع میانگین خطا MSE به مقایسه دقت آنها پرداختند. نتایج تحقیق نشان داد که مدل ترکیبی GARCH-ANN دارای خطای پیش‌بینی کمتری نسبت به سایر مدل‌های رقیب است.

وانگ^{۳۰} (۲۰۰۹) با استفاده از دو مدل GARCH و GJR-GARCH و GJR-GARCH-ANN به بررسی بازدهی سهام شاخص بورس تایوان از ۳ جون ۲۰۰۵ تا ۲۹ دسامبر ۲۰۰۹ پرداختند. سپس با استفاده از مدل‌های مذکور اقدام به پیش‌بینی شاخص کل بورس تایوان برای یک دوره یک هفته پرداخته و میزان خطا را با استفاده از معیارهای مجذور مربع خطاها RMSE و قدر مطلق میانگین خطا MAE و همچنین درصد قدر مطلق خطا^{۳۱} MAPE مقایسه کرد. یافته‌های تحقیق نشان داد که مدل ترکیبی GJR-GARCH-ANN در پیش‌بینی شاخص به عنوان مدل برتر انتخاب شد.

گورسن و کایاتلو^{۳۲} (۲۰۰۸) با استفاده از دو مدل ANN و مدل ترکیبی EGARCH-ANN به بررسی نوسانات شاخص بورس استانبول از جون ۲۰۰۳ تا مارس ۲۰۰۸ پرداخته و نحوه حرکت آن را برای مدت ۱۰ روز پیش‌بینی و نتایج را با استفاده از معیارهای قدر مطلق میانگین خطا MAE و مربع میانگین خطا MSE پیش‌بینی نمودند. نتایج تحقیق حاکی از برتری مدل EGARCH-ANN نسبت به سایر مدل‌های مورد مطالعه بود.

در مطالعه‌ای که با هدف بهبود پیش‌بینی با استفاده از شبکه عصبی مصنوعی و GARCH توسط بیلدریکو ارسین^{۳۳} (۲۰۰۸) انجام شد تغییرات سهام روزانه استانبول با داده‌های ۱۹۸۷-۲۰۰۸ به وسیله مدل‌های GARCH و ترکیبی پیش‌بینی شد و سپس نتایج مورد مقایسه قرار گرفتند. براین اساس مدل ترکیبی دارای کمترین خطای پیش‌بینی نسبت به مدل‌های GARCH و زیرمجموعه آن عملکرد بهتری داشتند

وانگ (۲۰۰۷) با استفاده از مدل‌های ترکیبی GJR-GARCH-ANN اقدام به مدل‌سازی بازدهی شاخص بورس تایوان از ۲۴ دسامبر ۲۰۰۱ تا ۳ فوریه ۲۰۰۵ و پیش‌بینی آن تا تاریخ ۲۹ دسامبر ۲۰۰۶ کرد. نتیجه این

مطالعه نشان داد مدل ترکیبی استفاده شده در این مطالعه، قدرت پیش‌بینی بالا و خطای کمتری نسبت به سایر مدل‌ها داشت.

در حوزه مطالعات داخلی مطالعات محدودی در خصوص استفاده از مدل‌های ترکیبی GARCH-ANN برای پیش‌بینی بازده نوسانات دارایی‌های مالی صورت گرفته است و صرفاً مدل‌های خانواده GARCH با مدل‌های شبکه عصبی مقایسه شده است. به عنوان نمونه نیز سعیدی و محمدی (۱۳۹۱) با استفاده از مدل‌های ترکیبی GARCH-ANN به پیش‌بینی نوسانات بازار بورس تهران در یک دوره ۱۲۶ ماهه طی سال‌های ۱۳۸۰-۹۰ پرداختند و نتایج حاصل از آن را از طرق گوناگون با مدل‌های GARCH مورد مقایسه قرار دادند. نتایج تحقیق نشان داد که مدل‌های ترکیبی از نظر دقت کمترین خطای پیش‌بینی را دارند. بررسی تغییرات جهت نوسانات نشان داد که مدل‌های ترکیبی با نوسانات واقعی نسبت به مدل‌های پایه‌ای GARCH همسویی بیشتری دارند. عمده پژوهش‌های انجام‌شده در این زمینه بر این نظر تأکید دارند که مدل‌های ترکیبی نسبت به مدل‌های دیگر در پیش‌بینی نوسانات کارایی بهتری دارد؛ بنابراین انجام دادن چنین پژوهش‌هایی باهدف تصحیح خطای پیش‌بینی در نوسان بازار سرمایه برای دریافت اطلاعات لازم مورد نیاز سرمایه‌گذاران است. پیش‌بینی تغییرپذیری یا نوسان در مدیریت ریسک، ارزش‌گذاری سبد سرمایه، قیمت‌گذاری مشتقات و ... کاربردهای فراوانی دارد؛ اما از دیدگاه معامله‌گران بازار مشتقات، درک نوسان‌پذیری، پیش‌بینی دقیق آن و حفاظت از سبد دارایی‌های در مقابل هزینه‌هایی که این متغیر به ارزش کل تحمیل می‌کند، از اهمیت دوچندانی برخوردار است.

۳- مدل‌های تحقیق و نحوه اندازه‌گیری متغیرها

مدل‌های مبتنی بر واریانس ناهمسانی شرطی یا ARCH در ابتدا توسط انگل^{۳۴} در سال ۱۹۸۲ معرفی شد بولر سلف^{۳۵} (۱۹۸۶) مدل انگل را تعمیم و گروهی از مدل‌ها را که به مدل‌های تعمیم‌یافته خود رگرسیون واریانس ناهمسان GARCH شهرت یافتند، ارائه کرد. از این پس، این مدل‌ها با تأکید بر ویژگی‌های مختلف داده‌های مالی گسترش یافتند که از آن جمله می‌توان به مدل‌های EGARCH، IGARCH^{۳۶} و ... اشاره کرد (جباری و نریمان، ۱۳۹۵). وجود ویژگی حافظه بلندمدت در بازدهی شاخص‌های سهام از موضوعاتی بوده که اخیراً به شدت مورد توجه قرار گرفته و به همین دلیل، علاوه بر مدل‌های یاد شده از مدل‌هایی که قلمر به توصیف این ویژگی هستند (مدل‌های FIGARCH و FIEGARCH) استفاده می‌شود. علاوه بر موارد ذکر شده در سال‌های اخیر با توسعه مدل‌های هوش مصنوعی، برخی محققین از این روش‌های برای پیش‌بینی قیمت سهام بهره بردند. یکی از شیوه‌های مناسب برای مدل‌سازی متغیرهای مالی استفاده از شبکه عصبی مصنوعی ANN^{۳۷} است که بدون محدود بودن به مدل‌های معین، می‌تواند خود را با نوسانات متغیرهای بازار هماهنگ و تعدیل نماید.

مدل‌های ARMA^{۳۸} و ARIMA^{۳۹}

یک فرآیند ARIMA(p,d,q) را برای متغیر X_t را به صورت زیر نمایش می‌دهند

$$\Phi(B)\Delta^d X_t = \theta_0 + \theta(B)\varepsilon_t \quad (1)$$

که یک فرآیند خود رگرسیونی انباشته با میانگین متحرک از مرتبه q, d, p است و به ترتیب نشان دهنده تعداد جملات خود توضیحی، مرتبه تفاضل گیری و تعداد جملات میانگین متحرک است و X_t را انباشته از مرتبه d می نامند که به صورت $I(d)$ نمایش داده می شود. در صورتی که d برابر با صفر شود، فرآیند ARIMA به ARMA تبدیل می شود. برای تخمین مدل های ARMA و ARIMA از روش باکس-جنکینز^{۴۰} استفاده می شود. در این روش تعداد جملات p و q با استفاده از توابع خود همبستگی^{۴۱} AC و خودهمبستگی جزئی^{۴۲} PAC محاسبه می شود و دقت آن ها با استفاده از معیارهای آکائیک^{۴۳} AIC، شوارتز-بیزین^{۴۴} SBC یا حنان-کوئین^{۴۵} HQIC محاسبه می شود و با هدف قرار دادن حداقل میزان این معیارها تعداد جملات q و p مشخص می گردد.

مدل های خانواده GARCH

برای ارائه یک تصویر مناسب از مدل های تلاطم میانگین شرطی و واریانس شرطی، بازدهی سری های زمانی به صورت r_t به شرط وجود اطلاعات Ω_{t-1} به صورت زیر نمایش داده می شود:

(۲)

$$r_t = \Phi_0 + \sum_{i=1}^p \Phi_i r_{t-i} - \sum_{i=1}^q \theta_i a_{t-i} + a_t$$

(۳)

$$E[r_t | \Omega_{t-1}] = \Phi_0 + \sum_{i=1}^p \Phi_i r_{t-i} - \sum_{i=1}^q \theta_i a_{t-i} + a_t$$

معادله بالا نشان دهنده مدل میانگین متحرک شرطی ARIMA است. در اینجا می توان متغیرهای برون زای دیگری به سمت راست معادله اضافه کرد (مثلاً اثرات تقویم فصل و متغیرهای مجازی). با استفاده از تعریف واریانس شرطی می توان این گشتاور مرتبه دوم را به صورت زیر برای r_t تعریف نمود.

(۴)

$$\sigma^2 = \text{var}(r_t | \Omega_{t-1}) = \text{var}(a_t | \Omega_{t-1})$$

به معادله واریانس شرطی (ARCH) برای نخستین بار توسط انگل ارائه شد. اگرچه مدل های ARCH به خاطر وجود سادگی دارای برتری اند اما در برخی موارد برای توصیف تلاطم ها^{۴۶} نیاز به تعداد قابل توجهی پارامتر a_t است. به همین خاطر بولرسلو مدلی را تعریف می کند که دارای پارامتر کمتری بوده و از نظر کفایت مشخصه نمایی مدل در وضعیت بهتری نسبت به مدل ARCH قرار دارد که به آن، مدل GARCH گفته می شود و به صورت زیر نمایش داده می شود:

$$; a_t = \sigma_t \varepsilon_t \quad (5)$$

$$r_t = \Phi_0 + \sum_{i=1}^p \Phi_i r_{t-i} - \sum_{i=1}^q \theta_i a_{t-i} + a_t$$

$$\sigma^2 = \omega_0 + \sum_{i=1}^m a_i a_{t-i}^2 + \sum_{j=1}^n \beta_j \sigma_{t-j}^2 \quad (6)$$

اگر معادله دارای ریشه واحد باشد به آن مدل GARCH انباشته یا IGARCH می‌گویند که مدل محدودشده‌ای از معادله (6) بوده و جمع پارامترهای آن برابر با واحد است:

$$\sum_{i=1}^m a_i + \sum_{j=1}^n \beta_j = 1 \quad (7)$$

ویژگی این مدل آن است که تأثیر یک شوک را به صورت ماندگار نمایش می‌دهد. گارچ نمایی EGARCH فرم دیگری از گارچ است که توسط نلسون^{۴۷} با لحاظ قرار دادن اثرات نامتقارن مثبت و منفی بر بازدهی‌ها نمایش می‌دهد. ساختار این مدل به صورت زیر تعریف شده است

$$\ln \sigma_{j,t}^2 = \omega_j + \beta_j \ln(\sigma_{t-1}^2) + \gamma \frac{|\varepsilon_{t-1}|}{|\sigma_{t-1}|} + a \left[\frac{|\varepsilon_{t-1}|}{|\sigma_{t-1}|} - \sqrt{\frac{2}{\pi}} \right] \quad (8)$$

که در آن واریانس شرطی و $\omega, \alpha, \beta, \gamma$ ضرایب است. این مدل نیاز به اعمال محدودیت بر پارامترهای مدل GARCH را از بین می‌برد که با تعریف واریانس شرطی در فرم لگاریتمی، واریانس همواره به صورت مثبت باقی می‌ماند. از این رو این مدل، این واقعیت را که شوک‌های منفی منجر به واریانس شرطی بزرگ‌تری نسبت به شوک‌های مثبت می‌شوند را می‌تواند توضیح دهد. بالی و همکاران^{۴۸} (۱۹۹۶) مدل FIGARCH را به منظور پوشش حافظه بلندمدت موجود در بازده سهام ارائه نمودند. با بازنویسی معادله بر اساس فرآیند ARMA برای ε_t^2 داریم:

$$[1 - a(L) - \beta(L)\varepsilon^2] = \omega + [1 - \beta(L)]v_t \quad (9)$$

که در آن $v_t = \varepsilon_t^2 - \sigma_t^2$ و نشان دهنده جز اخلاص برای واریانس شرطی است. برای اطمینان از اینکه واریانس شرطی غیر منفی باشد تمامی ریشه چندجمله‌ای $[1 - \beta(L)]$ خارج از دایره واحدند. هنگامی که چندجمله‌ای $[1 - a(L) - \beta(L)]$ دارای ریشه واحد باشد، فرآیند IGARCH(p,q) به صورت زیر تعریف می‌شود:

$$\phi(L)[1 - L]\varepsilon_t^2 = \omega + [1 - \beta(L)]v_t \quad (10)$$

در معادله بالا

$$\phi(L) = [1 - \alpha(L) - \beta(L)](1-L)^{-1} \quad (11)$$

برای در نظر گرفتن هم انباشتگی بلندمدت در نوسانات معادله به یک فرآیند FIGARCH(p,d,q) به صورت زیر تعریف می گردد:

$$\phi(L)(1-L)^d \varepsilon_t^2 = \omega + [1 - \beta(L)]v_t \quad (12)$$

که واریانس شرطی در آن به صورت زیر تعریف می شود:

$$\sigma_t^2 = \frac{\omega}{\beta(L)} + \left[1 - \frac{\phi(L)}{\beta(L)} (1-L)^d \right] \varepsilon_t^2 \quad (13)$$

که d می تواند مقادیری بین صفر و یک داشته باشد و تمامی ریشه های $\phi(L)$ و $[1 - \beta(L)]$ خارج ارز دایره واحدند. در این مدل ها آثار شوک های وارد شده به واریانس شرطی به طور نمایی میرا شده و واکنش واریانس شرطی به شوک های گذشته با نرخ هیپربولیکی میرا می شود. میدانیم که مدل EGARCH می تواند به صورت یک فرآیند ARMA برحسب لگاریتم واریانس شرطی نمایش داده شود. با در نظر گرفتن مدل انباشته کسری برای EGARCH بلرسو و میکلس^{۴۹} مدل FIEGARCH بصورت زیر تعریف می شود:

$$z_t = \varepsilon_t / \sqrt{\sigma_t^2} \ln(\sigma_t^2) = \omega_t + \phi(L)^{-1} (1-L)^{-d} [1 + a(L)] g(z_{t-1}) \quad (14)$$

$$g(z_t) = \gamma_1 z_t + \gamma_2 [|z_t| - E|z_t|] \quad (15)$$

که در آن $\phi(L)$ همانند مدل FIGARCH تعریف می شود و در صورت $\gamma \neq 0$ امکان وجود اثرات اهرمی را فراهم می آورد. این فرآیند نیز برای $0 < d < 1$ مانا است. وجود مقدار $-0.5 < d < 0.5$ برای این فرآیند نشان دهنده میرا بودن اثر شوک ها در این مدل است.


حافظه بلندمدت و انباشتگی کسری

یکی از ویژگی های مشاهده شده در بسیاری از داده های سری زمانی مالی، وجود حافظه بلندمدت در میانگین و واریانس شرطی آن ها است. بدین صورت که اثر شوک های وارد شده بر سری های زمانی دیرپا بوده و مدت زمان زیادی طول می کشد که اثر این شوک ها در بازدهی دارایی و تلاطم آن ها از بین برود. یک روش برای مدل سازی چنین رفتاری در این سری ها استفاده از فرآیند انباشته کسری است که این مدل ها می تواند مانا یا نامانا باشد و حتی زمانی که این فرآیندها به طور ضعیف مانا هستند، دارای توابع خودهمبستگی هستند که به تدریج به صفر میل می کند و در واقع دارای حافظه بلندمدت اند. این فرآیندها می تواند هم در مدل های میانگین شرطی به کار برده

شوند که در این صورت این فرآیندها را ARFIMA و هم در فرآیند واریانس شرطی به‌کاربرده شود که به‌صورت انباشتگی شرطی نوسانات FIGARCH و FIEGARCH مورد استفاده قرار گیرند. با توجه به ویژگی‌های سری زمانی باوجود حافظه بلندمدت در سری‌های زمانی آزمون‌های گوناگونی برای تشخیص وجود حافظه بلندمدت در سری‌های زمانی وجود دارد که در این پژوهش از آزمون $R/S^{\Delta 1}$ و $GPH^{\Delta 1}$ استفاده شده است.

شبکه عصبی

شبکه‌های عصبی به‌طور معمول توسط سه لایه معرفی می‌شوند: لایه ورودی $\Delta 2$ که اولین لایه در شبکه‌های عصبی بوده و دریافت‌کننده منابع خارج از سیستم و متغیرهای مستقل در مدل‌های رگرسیونی هستند. دومین لایه، لایه مخفی $\Delta 3$ است که بین لایه‌های ورودی و خروجی قرار دارد. این لایه هیچ مفهومی را بیان نمی‌کند و فقط یک نتیجه میانی در فرایند محاسبه‌ی ارزش خروجی است و هم‌تایی در اقتصادسنجی ندارند. سرانجام لایه خروجی $\Delta 4$ که نشان‌دهنده متغیرهای وابسته در مدل‌های رگرسیون هستند. مدل‌های شبکه عصبی انواع مختلفی دارند. متداول‌ترین ساختار شبکه عصبی که در پژوهش‌ها استفاده می‌گردد ساختار شبکه پرسپرون چندلایه $\Delta 5$ MLP است. به‌طور معمول یک شبکه عصبی MPL با یک لایه مخفی تابعی به‌صورت $f: R^D \rightarrow R^L$ که در آن D اندازه لایه‌های ورودی بردار x و L اندازه خروجی بردار $f(x)$ است به‌صورت گرافیکی به شکل زیر نمایش داده می‌شود:



شکل (۱) شبکه عصبی MPL

به‌صورت ماتریسی:

$$f(x) = G(b^2 + W^2(s(b^1 + W^1x))) \quad (16)$$

b^1, b^2 بردارهای انحراف $\Delta 6$ و W^1, W^2 ماتریس‌های وزنی، G و s توابع فعال‌سازی‌اند. فرم ریاضی لایه پنهانی بصورت زیر می‌باشد:

$$h(x) = \Phi(x) = s(b^1 + W^1x) \quad (17)$$

در معادله فوق، $W^1 \in R^{D \times D_h}$ ماتریس وزنی است که رابط بین متغیرهای ورودی و لایه های پنهان است. هر ستون W^1 وزنی را از داده های ورودی به لایه مخفی i -ام اختصاص می دهد. انتخاب معمول برای s شامل تاوانت هیپربولیک $\tanh(a) = \frac{(e^a - e^{-a})^{-i}}{(e^a + e^{-a})}$ یا تابع سیگموئید $\text{sigmoid}(a) = \frac{1}{1 + e^{-a}}$ است که هر دو تابع اساکلر هستند اما لگاریتم طبیعی آن ها به بردار و تانسورهای⁵⁷ تبدیل می شوند که می تواند هر عنصر را در خود جای دهد. به طور مشخص هر عنصر روی بردار قادر به تولید برداری منحصر به فرد است) در نهایت فرم بردار خروجی بصورت زیر می باشد:

$$o(x) = G(b^2 + W^2h(x)) \quad (18)$$

فرایند یادگیری در شبکه عصبی در واقع برآورد وزن ها و پارامترهای مدل است که به دو صورت یادگیری با نظارت⁵⁸ و بدون نظارت⁵⁹ انجام می شود. اصل یادگیری در شبکه های عصبی با تکرار انجام می شود. مشهورترین یادگیری با نظارت الگوریتم پس انتشار خطاست⁶⁰ که در پژوهش حاضر از این روش استفاده شده است.

توزیع نرمال، تی-استیودنت و خطای تعمیم یافته (GED)

به طور تجربی در محاسبه مدل های دارای تلاطم فرض بر آن است که جملات خطا از سه توزیع نرمال، t -Student و GED پیروی می کند. تابع احتمال تجمعی⁶¹ PDF⁶¹ توزیع نرمال برای متغیر تصادفی z به صورت زیر است:

$$F(z) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(z-\mu)^2}{2\sigma^2}\right) \quad (19)$$

که در آن μ و σ به ترتیب نشان دهنده میانگین و واریانس است به همین ترتیب تابع احتمال تجمعی توزیع t -Student به صورت زیر می باشد:

$$F(z, \mu, \sigma, \nu) = \frac{C}{\sigma^2} \left(1 + \frac{(z-\mu)^2}{\sigma^2(\nu-2)}\right)^{-\frac{(\nu+1)}{2}} \quad (20)$$

در معادله شماره (20) μ میانگین و σ واریانس و ν به عنوان درجه آزادی استفاده می گردد. در این معادله پارامتر C به صورت زیر تعریف می شود:

$$C = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\mu(\nu-2)}\Gamma\left(\frac{\nu+1}{2}\right)} \quad (21)$$

که $\Gamma(\cdot)$ نشان دهنده تابع گاما است و پارامتر ν ضخامت و کشیدگی تابع چگالی را کنترل می‌کند. تابع احتمال تجمعی GED به صورت زیر نمایش داده می‌شود:

$$F(z_t, \mu, \sigma, \beta) = \frac{\beta}{2\sigma\Gamma(1/\beta)} \exp\left(-\left(\frac{|z_t - \mu|^\beta}{\sigma}\right)\right) \quad (22)$$

σ و μ به ترتیب نشان دهنده میانگین و واریانس و β کنترل کننده ناهمواری و میزان کلفتی و لاغر بودن رفتار دامنه z_t توزیع را مشخص می‌کند. میزان $+\infty$ ، صفر و -2 برای β به ترتیب نشان دهنده کشیدگی مثبت^{۶۳}، نرمال^{۶۴} و منفی^{۶۵} است.

معیارهای ارزیابی پیش‌بینی‌ها

برای بررسی عملکرد مدل‌های پیش‌بینی شاخص بازار سهام پس از تخمین و پیش‌بینی این مدل‌ها، میزان خطای مقادیر واقعی نسبت به مقادیر پیش‌بینی شده با استفاده از معیارهای مربع میانگین خطا MSE، مجذور میانگین خطا RMSE و قدر مطلق میانگین خطا MAE محاسبه خواهد شد تا براساس آنها، مدل بهینه براساس میزان کمتر خطای پیش‌بینی انتخاب شود. مدل‌های مورد نظر به صورت زیر نمایش داده می‌شود:

(۲۳)

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

(۲۴)

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}$$

(۲۵)

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|$$

که y_i نشان دهنده مقادیر واقعی و \hat{y}_i نشان دهنده مقادیر پیش‌بینی شده است و m نیز به عنوان تعداد مشاهدات در نظر گرفته شده است.

مدل ترکیبی

با توجه به تجربیات مطالعات پیشین در بخش «۲» به نظر می‌رسد ترکیب مدل‌های بیان شده در بخش «۳» به عنوان مدلی در پیش‌بینی سری زمانی عملکرد بهتری نسبت به پیش‌بینی صورت گرفته با استفاده از هر یک از این مدل‌ها خواهد داشت. بنابراین روشی که برای پیش‌بینی نوسان شاخص بورس از ترکیب دو مدل مطرح شده

در بخش های بالا پیشنهاد شد، به این ترتیب که در مرحله نخست با استفاده از مدل های ARIMA سری میانگین شرطی سری زمانی شاخص کل بورس تخمین زده می شود. سپس واریانس شرطی با استفاده از مدل های خانواده GARCH براساس سه توزیع نرمال، تی-استیودنت و GED تخمین زده می شوند و به عنوان ورودی شبکه عصبی به همراه دو متغیر کنترلی نرخ دلار و قیمت نفت استفاده می گردد. در طراحی شبکه عصبی MPL باتابع فعال سازی پرسپترون^{۶۶} که یکی از رایج ترین مدل ها در چارچوب مطالعات مالی است با ترکیب وزنی n متغیر ورودی از مجموعه نرون هایی استفاده شده که وظیفه پردازش اطلاعات را بر عهده دارند و از لحاظ ریاضی به صورت زیر است:

$$y_j = \sum_{i=1}^n w_{ij} x_i - \theta \quad , \quad z = \psi(y) \quad (26)$$

که x_i متغیر ورودی نام و w_{ij} اوزان شبکه است و y_j در این به عنوان ورودی خالص در نظر گرفته می شود و همچنین θ به عنوان حد آستانه خارجی است. همچنین تابع z به عنوان خروجی در نظر گرفته می شود. تابع فعال سازی در این شبکه تابع فعال ساز سیگموئید است. در این مقاله از خروجی های مدل های خانواده GARCH و دو متغیر نفت و دلار به عنوان نرون های ورودی و از یک لایه پنهان شامل ۲۰ نرون و یک نرون خروجی و همچنین نسبت آموزش به یادگیری ۰/۹ به ۰/۱ استفاده می شود. به صورت ریاضی با توجه به معادله شماره (۶) ورودی شبکه عصبی به صورت ترکیبی از خروجی مدل GARCH است که به صورت زیر نمایش داده می شود:


$$\sigma^2 = \sigma_t^2 + \varepsilon_{t-1}^2 \quad (27)$$

حال این خروجی را به همراه دو متغیر کنترلی نفت و دلار به عنوان ورودی نرون شبکه عصبی به کار می بریم:

$$X = \sigma_i^2 r_{i,oil} r_{i,dollar} \quad (28)$$

$$Y_j = \sum_{i=1}^n w_{ij} X_i - \theta \quad (29)$$

که در آن w_{ij} اوزان شبکه است که برابر با ضرائب موجود در مدل GARCH به صورت a و β است و در نهایت خروجی آن به صورت تابع z به دست می آید، مدل های دیگر خانواده GARCH نیز به همین صورت به عنوان ورودی در نظر گرفته می شوند. پس از این کار نتایج مدل های خانواده GARCH و مدل ترکیبی با استفاده از شاخص های RMSE و MAE و MSE با مقادیر واقعی سنجدیده شده و در نهایت با یکدیگر مقایسه و مدل برتر انتخاب می گردد. ساختار این الگو در شکل زیر آورده شده است:



شکل (۲): ساختار مدل ترکیبی

۴- یافته‌های پژوهش

داده‌ها و آزمون‌های اولیه

داده‌های مورد استفاده در این پژوهش شاخص کل بورس اوراق بهادار تهران است که به صورت روزانه از سال ۱۳۹۶/۱۰/۲۶ تا ۸۷/۹/۲۳ به تعداد ۲۱۹۶ مشاهده جمع‌آوری شده است. همچنین در این پژوهش از دو متغیر کنترلی قیمت نفت اوپک و نرخ دلار به قیمت بازار آزاد استفاده شده است. در ابتدا سری زمانی بازدهی این سه متغیر به صورت زیر استخراج می‌شود:

$$r_t = \frac{P_t - P_{t-1}}{P_t} \times 100 \quad (30)$$

که در آن r_t بازدهی و P_{t-1} به ترتیب شاخص قیمت روز جاری و روز قبل شاخص این سه متغیر است. آمار توصیفی این سری‌ها به همراه بازدهی آن‌ها در جدول شماره یک آورده شده است.

جدول (۱): آمار توصیفی داده‌ها

آماره / داده	شاخص کل	بازدهی شاخص کل	نفت	بازدهی نفت	دلار	بازدهی دلار
میانگین	۴۷۹۰۳,۸۲	۰,۱۱۱۶۳۷	۷۷,۴۵۱۰۴	۰,۰۴۸۲۰۴	۲۵۳۲۱,۷۴	۰,۰۷۴۳۳
میانه	۵۳۴۸۵,۵۵	۰,۰۴۵۱۶۴	۷۵,۵۶	۰,۰۱۴۲۱۲	۳۱۱۵۰	۰
بیشینه	۹۸۵۹۶,۹	۵,۴۰۱۶۹	۱۲۴,۶۴	۴۳,۸۱۵۸۱	۴۴۲۹۰	۱۷,۰۹۲۸۷
کمینه	۷۹۵۵,۴	۵,۵۱۲۵۰۹-	۲۲,۴۸	۱۰۰-	۹۶۵۰	۹,۵۲۳۸۱-
انحراف معیار	۲۷۹۸۳,۹۶	۰,۶۹۱۷۲۳	۲۷,۴۳۰۱۵	۳,۶۳۹۶۷۹	۱۱۴۴۵,۴۷	۱,۱۷۴۳۷۴
چولگی	۰,۰۲۹۳۶-	۰,۴۰۰۵۶	۰,۰۶۳۱۰۱-	۱۸,۱۳۹۷۱-	۰,۳۰۰۱۲۴-	۱,۴۳۸۴۲۱
کشیدگی	۱,۳۶۷۲۱۱	۸,۵۴۸۶۶۳	۱,۵۳۸۰۱۴	۵۲۹,۵۰۵۱	۱,۳۶۸۴۶۶	۳۷,۶۸۱۷۲
آماره جاک برا	۲۴۴,۲۵۴۶	۴۴۸۶,۲۸۷	۱۹۶,۹۳۹۹	۲۵۴,۶۱۷۲۱	۲۷۶,۵۳۱۳	۱۱۰,۷۶۵
احتمال	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰

با نگاهی بر این ویژگی‌ها متوجه می‌شویم که این داده‌ها دارای کشیدگی مثبتی است که میزان آن همراه با چولگی نمایش داده شده است. همچنین اختلاف میانگین و انحراف معیار نشان‌دهنده وجود نوسان در طول دوره بررسی است. در نهایت آماره جاک-برا^{۶۷} و میزان احتمال آن نشان‌دهنده عدم نرمال بودن در شاخص‌ها و بازدهی آن‌ها است.

با استفاده از سه آزمون دیکی-فولر تعمیم‌یافته^{۶۸} و فیلپس پرون^{۶۹} و KPSS^{۷۰} به بررسی مانایی داده‌ها پرداخته شد. در دو آزمون اول فرض صفر مبنی بر وجود ریشه واحد است ولی در آزمون KPSS این فرض برعکس می‌شود. نتایج حاصل از آماره محاسبه شده در این سه آزمون نشان‌دهنده رد فرض صفر در دو آزمون اول و قبول این فرضیه در آزمون KPSS می‌شود. بنابراین مانا بودن بازدهی این سری از داده‌ها تأیید گردید.

بررسی وجود حافظه بلندمدت

قبل از تخمین داده‌ها، ابتدا لازم است اثر وجود حافظه بلندمدت را بر روی بازده در قسمت میانگین شرطی داده‌ها بررسی گردد. برای بررسی وجود حافظه بلندمدت از دو آزمون R/S و GPH استفاده شد که نتایج حاصل در جدول زیر نشان داده شده است.

جدول (۲): بررسی وجود حافظه بلند مدت

آماره	آزمون
۲,۰۸	R/S
۰,۱۶۱	GPH

نتایج این آزمون نشان‌دهنده عدم وجود حافظه بلندمدت در قسمت میانگین بازدهی این سری از داده‌ها است. بنابراین مدل ARMA مدل مناسبی برای تخمین میانگین است.

آزمون ضریب لاگرانژ^{۱۱}

پس از تخمین مدل میانگین شرطی، جهت بررسی وجود اثر ARCH با انجام آزمون ضریب لاگرانژ بر روی پسماندهای سری زمانی بازده شاخص کل و بررسی آماره F و χ^2 مشاهده می‌شود که این بازده دارای اثرات ARCH است. به این معنی که واریانس‌های جمله خطا دارای خودهمبستگی هستند.

جدول (۳): آزمون ضریب لاگرانژ ARCH

احتمال	آماره آزمون	آزمون
۰,۰۰۰	۸۰,۸۹۰۹	F - statistic
۰,۰۰۰	۳۴۲,۳۱۵	Chi - squared

تخمین مدل‌های خانواده GARCH

در ادامه ۴ مدل از خانواده GARCH بر اساس سه توزیع نرمال، GED و GED برآورد گردیده که در مجموع به ۱۲ مدل رسید. جدول زیر نشان‌دهنده این مدل از میانگین و واریانس شرطی است.

جدول (۵): مدل میانگین واریانس‌های برآورد شده بازده شاخص کل بورس اوراق بهادار

مدل	توزیع	میانگین شرطی	واریانس شرطی
GARCH	نرمال	$y_t = 0.018 + 0.402y_{t-1}$ (۱.۰۶) (۱۷.۹)	$\sigma_t^2 = 0.024 + 0.194\varepsilon_{t-1}^2 + 0.763\sigma_{t-1}^2 + 0.001v_{oil} + 0.001v_{dollar}$ (۲.۳۱) (۳.۲۶) (۱۰.۸) (۰.۰۰۱) (۰.۰۰۱)
	T	$y_t = 0.043 + 0.925y_{t-1} - 0.518u_{t-1} - 0.284u_{t-2}$ (۲.۰۷) (۴۰.۷۶) (-۱۵.۷۹) (-۱۰.۶۳)	$\sigma_t^2 = 0.005 + 0.194\varepsilon_{t-1}^2 + 0.834\sigma_{t-1}^2 + 0.001v_{oil} + 0.001v_{dollar}$ (۲.۵۹) (۶.۰۱) (۳۶.۱۱) (۰.۰۰۱) (۰.۰۰۳)
	GED	$y_t = 0.050 + 0.933y_{t-1} - 0.539u_{t-1} - 0.284u_{t-2}$ (۳.۱۸۴) (۵۳.۴۶) (-۳۳.۰۰) (-۱۱.۲۱)	$\sigma_t^2 = 0.007 + 0.186\varepsilon_{t-1}^2 + 0.821\sigma_{t-1}^2 + 0.001v_{oil} + 0.001v_{dollar}$ (۳.۰۱) (۵.۷۷) (۲۹.۷۲) (۰.۰۰۱) (۰.۰۰۲)
EGARCH	نرمال	$y_t = 0.050 + 0.931y_{t-1} - 0.590u_{t-1} - 0.366u_{t-2}$ (۰.۳۱) (۲۹.۸۷) (-۱۵.۳۰) (-۷.۰۹)	$\ln \sigma_t^2 = -0.053 + 0.328 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } + 0.0620 \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + 0.933 \ln \sigma_{t-1}^2 - 0.029v_{oil} + 0.008v_{dollar}$ (-۴.۰۵) (۴.۳۸) (۸۵.۸۴) (۱۰.۰۶) (-۴.۶۲) (۰.۵۷)

مدل	توزیع	میانگین شرطی	واریانس شرطی
FIGARCH	T	$y_t = 0.056 + 0.916y_{t-1} - 0.523u_{t-1} - 0.275u_{t-2}$ (۳.۰۳) (۴۵.۴۱) (-۱۷.۶۲) (-۱۲.۳۳)	$\ln \sigma_t^2 = -0.025 + 0.275 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } + 0.050 \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + 0.927 \ln \sigma_{t-1}^2 - 0.008v_{oil} + 0.019v_{dollar}$ (-۲.۶۱) (۳.۰۸) (۱۳۶.۴۲) (۷.۲۷) (-۱.۳۵) (۱.۳۹)
	GED	$y_t = 0.058 + 0.923y_{t-1} - 0.538u_{t-1} - 0.279u_{t-2}$ (۵.۹۰) (۴۸.۶۶) (-۱۹.۲۷) (-۱۴.۵۸)	$\ln \sigma_t^2 = -0.041 + 0.279 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } + 0.057 \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + 0.936 \ln \sigma_{t-1}^2 - 0.014v_{oil} + 0.015v_{dollar}$ (-۳.۴۳) (۳.۳۷) (۳.۲۷) (۷.۲۸) (-۲.۱۳۵) (۰.۹۵)
	نرمال	$y_t = 0.039 + 0.325y_{t-1} - 0.089u_{t-1}$ (۲.۴۵) (۱۷.۳۲) (-۱۵.۳۹)	$\sigma_t^2 = 0.468 + 0.285\sigma_{t-1}^2 + [1 - (1 - 0.258L)^{-1}(1 - 0.238L)(1 - L)^{0.368}] \varepsilon_t^2 - 0.002v_{oil} + 0.010v_{dollar}$ (۳.۱۲) (۸.۱۴) (۴.۶۵) (۷.۱۲) (-۰.۲۹) (۰.۱۵)
FIGARCH	T	$y_t = 0.039 + 0.396y_{t-1}$ (۲.۶۹) (۱۵.۹۶)	$\sigma_t^2 = 0.526 + 0.577\sigma_{t-1}^2 + [1 - (1 - 0.577L)^{-1}(1 - 0.238L)(1 - L)^{0.558}] \varepsilon_t^2 + 0.003v_{oil} + 0.003v_{dollar}$ (۲.۱۹) (۸.۰۵۳) (۶.۳۶) (۶.۳۲) (-۰.۲۹) (۰.۱۷)
	GED	$y_t = 0.043 + 0.294y_{t-1} - 0.015u_{t-1}$ (۳.۶۹) (۱۸.۰۳) (۱۲.۰۱)	$\sigma_t^2 = 0.652 + 0.451\sigma_{t-1}^2 + [1 - (1 - 0.451L)^{-1}(1 - 0.160L)(1 - L)^{0.502}] \varepsilon_t^2 + 0.082v_{oil} + 0.033v_{dollar}$ (۴.۲۱) (۸.۰۵) (۶.۴۲) (۵.۲۳) (-۰.۸۷) (۰.۴۲)
	نرمال	$y_t = 0.054 + 0.324y_{t-1} + 0.071u_{t-1}$ (۵.۹۸) (۳۳.۴۳) (۱۲.۷۰)	$\ln(\sigma_t^2) = 0.721 + 0.576(L)^{-1}(1 - L)^{-0.402}[1 + 0.147(L)](0.088 \frac{\varepsilon_{t-1}}{ \sigma_{t-1} } + 0.338 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } - E \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} }) - 0.019v_{oil} + 0.076v_{dollar}$ (۶.۷۲) (۷۳.۵۴) (۱.۱۹) (۴۳.۸۲) (۱.۹۱) (۶.۴۳) (-۰.۷۵) (۰.۱۳)
FIGARCH	T	$y_t = 0.059 + 0.935y_{t-1} - 0.520u_{t-1} - 0.315u_{t-2}$ (۲.۵۵) (۴۲.۲۰) (-۱۴.۴۹) (-۱۰.۵۶)	$\ln(\sigma_t^2) = 0.802 + 0.934(L)^{-1}(1 - L)^{0.504}[1 + 0.260(L)](0.052 \frac{\varepsilon_{t-1}}{ \sigma_{t-1} } + 0.488 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } - E \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} }) - 0.001v_{oil} + 0.033v_{dollar}$ (۱.۳۹) (۱۷۲.۵) (۱.۸۱) (-۱۴.۶۲) (۱.۴۱) (۷.۹۹) (-۰.۲۵) (۰.۸۴)
	GED	$y_t = 0.067 + 0.928y_{t-1} - 0.539u_{t-1} - 0.292u_{t-2}$ (۲.۳۲) (۴۱.۴۰) (-۱۶.۳۴) (-۱۳.۱۶)	$\ln(\sigma_t^2) = 0.883 + 0.457(L)^{-1}(1 - L)^{-0.679}[1 - 0.324(L)](0.088 \frac{\varepsilon_{t-1}}{ \sigma_{t-1} } + 0.421 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } - E \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} }) - 0.001v_{oil} + 0.033v_{dollar}$ (۳.۸۹) (۱۷۸.۱۵) (۱۷۸.۱۵) (۱۷۸.۱۵) (۱.۱۲) (۷.۴۳) (-۰.۲۳) (۰.۸۳)

با نگاهی به مدل های برآورد شده از خانواده های GARCH با سه توزیع نرمال، GED و مشاهده می شود که واریانس شرطی از ساختار خانواده GARCH پیروی کرده و تفسیرهای مدل های انجام شده به ترتیب در زیر انجام می شود:

- در مدل های GARCH بر اساس سه توزیع نرمال، GED تفاوت زیادی بین مدل های میانگین و واریانس شرطی مشاهده نمی شود و ضرایب در این مدل به جز دو متغیر کنترلی معنادار هستند. عدم معنی داری این دو متغیر در این مدل نشان دهنده عدم اثرپذیری بر روی ضرایب ARCH و GARCH است که نشان دهنده عدم تغییر در واریانس شرطی مدل است. معنی داری ضرایب ARCH و GARCH در این مدل به معنای پیروی بازدهی شاخص اصلی بورس از این مدل ها است.

- در مدل EGARCH بر اساس سه توزیع نرمال، و GED همانند قبل تفاوت چندانی میان میانگین و واریانس شرطی مشاهده نمی‌شود و در این مدل ضریب واریانس دلار در هر سه توزیع بی‌معنی است و با توجه به معنی‌داری ضریب $\frac{\sigma_t^2 - 1}{\sigma_{t-1}^2}$ نشان‌دهنده واکنش نامتقارن بازده شاخص کل به شوک‌های خارجی و دارای اثر اهرمی^{۲۲} است، تاثیر گذاری غیر یکسان شوک‌های مثبت و منفی بر شاخص بازار بورس نشان می‌دهد که این خود نشان دهنده تاثیرپذیری بورس ایران از اخبار و شوک‌های خارجی است. همچنین معنی‌داری واریانس قیمت نفت در این مدل نشان‌دهنده سرایت تأثیر نوسانات قیمت نفت بر نوسانات بازدهی شاخص بورس است.
- پس از تخمین این مدل‌ها به دلیل وجود اثرات ARCH در باقیمانده مدل و اینکه این اثرات می‌تواند ناشی از وجود حافظه بلندمدت باشد مدل‌های خود را با در نظر گرفتن این اثر به صورت FIGARCH تخمین زده شد. در این مدل تمامی ضرایب به جز نفت و دلار معنی‌دار هستند. معنادار بودن اثرات میانگین نشان‌دهنده این است که بازدهی هر دوره به صورت ضریبی از بازدهی و شوک‌های دوره قبل است و در قسمت واریانس شرطی معنی‌داری نشان‌دهنده وابستگی به تلاطم و شوک‌های دوره قبل است. همچنین بی‌معنی بودن ضرایب نفت و دلار در این مدل‌ها نشان‌دهنده عدم تأثیر این دو متغیر در درازمدت بر روی این مدل‌ها است.
- در مدل FIEGARCH نیز به همین ترتیب نشان‌دهنده وجود تلاطم و اثر اهرمی است در واقع تأثیر گذاری این اثرات بر بلندمدت بر بازدهی شاخص اصلی بورس به معنای تأثیر و ماندگاری اخبار و شوک‌های خارجی در بلندمدت بر شاخص اصلی بورس ایران است، ولی بی‌معنی بودن ضرایب نفت و دلار در این مدل‌ها نیز نشان‌دهنده عدم تأثیر نوسان این دو مورد بر شاخص اصلی بورس در بلندمدت است.

مدل ترکیبی

با توجه به مباحث مطرح‌شده، پس از تعیین وقفه‌های مناسب شبکه‌ای که دارای کمترین خطا بود، لایه ورودی با توجه به داده‌های ورودی سه نرون (خروجی خانواده GARCH، قیمت نفت و نرخ دلار) در نظر گرفته شد. همچنین خروجی‌های این شبکه دارای یک نرون است. پس از تعیین ورودی‌های این شبکه، تعداد دوره‌های آموزش و آزمایش این شبکه به نسبت ۹۰ به ۱۰ درصد تعیین و با نرخ یادگیری ۱ درصد استفاده شد. در نهایت خروجی‌های این مدل به همراه خروجی‌های مقادیر واقعی سنجش و میزان خطای آن‌ها برحسب مقدار RMSE و MAE و MSE محاسبه و نتایج زیر حاصل گردید. شایان ذکر است پیش‌بینی نهایی بازدهی شاخص کل با تجمیع پیش‌بینی مدل میانگین شرطی (ARMA) و پیش‌بینی هر یک مدل‌های اشاره شده در فوق محاسبه شد.

طراحی مدلی جهت پیش بینی بازده شاخص بورس (با تاکید بر مدل های ترکیبی ...)/ رضا نجارزاده، مهدی ذوالفقاری و صمد غلامی

جدول (۶) خطای پیش بینی بر اساس معیار RMSE

مدل	گام	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
GARCH-N		۰.۰۰۶۵۶	۰.۱۴۸۳۵	۰.۱۶۲۶۵	۰.۱۴۲۴۳	۰.۱۲۸۷۴	۰.۱۲۹۳۲	۰.۱۱۹۱۹	۰.۱۴۲۰۱	۰.۱۷۶۹۸	۰.۲۱۲۳۳
GARCH-t		۰.۱۱۴۵۶	۰.۲۱۶۵	۰.۱۹۹۳۴	۰.۱۷۲۱۲	۰.۱۵۴۴۴	۰.۱۵۱۳۴	۰.۱۴۰۳۹	۰.۱۶۰۶۶	۰.۱۹۶۱۶	۰.۲۳۰۴۹
GARCH-GED		۰.۰۸۵۵۴	۰.۳۱۷۳۲	۰.۲۹۴۱۴	۰.۲۶۵۶۶	۰.۲۳۷۵۹	۰.۲۴۸۸۷	۰.۲۳۱۳	۰.۲۵۰۸۴	۰.۲۹۳۰۹	۰.۳۴۳۳۴
ANN-GARCH-N		۰.۱۵۶۸۷	۰.۱۵۹۹۸	۰.۱۶۱۱۳	۰.۱۶۴۷۶	۰.۱۶۷۲۵	۰.۱۶۹۵۶	۰.۱۷۲۳۴	۰.۱۷۵۱۲	۰.۱۷۸۹۸	۰.۱۸۱۶۶
ANN-GARCH-t		۰.۰۴۲۱۳	۰.۰۴۴۵۵	۰.۰۷۶۳۲	۰.۰۷۴۹۹۴	۰.۰۸۱۲۱۲	۰.۰۷۳۵۶	۰.۰۵۵۲۲	۰.۰۷۸۳۴	۰.۰۹۰۱۸	۰.۰۷۲۲۷
ANN-GARCH-GED		۰.۱۸۳۱۵	۰.۱۸۹۴۳	۰.۱۹۴۷۷	۰.۱۹۹۳۴	۰.۲۰۵۶۵	۰.۲۱۱۱۳	۰.۲۱۷۰۰	۰.۲۲۳۵۴	۰.۲۳۰۳۴	۰.۲۳۷۳۲
EGARCH-N		۰.۰۰۹۶۷	۰.۱۵۹۳۹	۰.۱۶۷۶۸	۰.۱۴۷۵۹	۰.۱۳۲۷۳	۰.۱۳۴۵۴	۰.۱۲۴۳۲	۰.۱۴۵۵۱	۰.۱۷۸۶۰	۰.۲۱۳۷۵
EGARCH-t		۰.۰۵۷۵۵	۰.۲۹۵۳۴	۰.۲۸۶۴۳	۰.۲۵۵۱۲	۰.۲۲۸۸۶	۰.۲۳۶۷۶	۰.۲۱۹۴۵	۰.۲۴۵۴۶	۰.۲۹۳۲۳	۰.۳۴۷۳۲
EGARCH-GED		۰.۰۸۹۰۸	۰.۲۲۳۹۲	۰.۲۰۱۷۹	۰.۱۷۵۴۹	۰.۱۵۷۰۳	۰.۱۵۶۴	۰.۱۴۵۹۵	۰.۱۶۳۴۸	۰.۱۹۸۸	۰.۲۳۴۱۲
ANN-EGARCH-N		۰.۱۵۸۰۸	۰.۱۶۲۵۱	۰.۱۶۷۰۴	۰.۱۷۱۶۶	۰.۱۷۶۳۶	۰.۱۸۱۳	۰.۱۸۶۰۱	۰.۱۹۰۹۵	۰.۱۹۵۹	۰.۲۰۱۰۴
ANN-EGARCH-t		۰.۰۱۴۲۹	۰.۰۱۳۷۰	۰.۰۱۳۱۱	۰.۰۱۲۵۱	۰.۰۱۱۹۲	۰.۰۱۱۸۴۳۳	۰.۰۷۰۷۶	۰.۰۸۰۲۱	۰.۰۷۹۶	۰.۰۸۹۳۰
ANN-EGARCH-GED		۰.۰۸۳۱۴	۰.۰۸۳۵۲	۰.۰۸۳۹۰	۰.۰۸۴۲۹	۰.۰۸۴۶۹	۰.۰۸۵۰۹	۰.۰۸۵۵۱	۰.۰۸۵۹۳	۰.۰۸۶۳۶	۰.۰۸۶۸۰
FIGARCH-N		۰.۰۰۰۲۷	۰.۲۵۳۸۳	۰.۲۷۷۷۷	۰.۲۴۳۲۵	۰.۲۱۹۶۱	۰.۲۰۵۸	۰.۲۰۴۲۲	۰.۲۴۲۸۴	۰.۳۰۱۱۷	۰.۳۶۱۵۸
FIGARCH-t		۰.۰۰۰۱۳	۰.۲۵۶۲۶	۰.۲۷۷۸۰	۰.۲۴۳۵۸	۰.۲۱۹۶۷	۰.۲۱۳۲۲	۰.۲۰۴۹۰	۰.۲۴۲۴۶	۰.۳۰۰۰۲	۰.۳۵۹۹۳
FIGARCH-GED		۰.۰۳۸۰۰	۰.۲۴۹۵۳	۰.۲۷۵۱۸	۰.۲۴۱۲۰	۰.۲۱۷۶۳	۰.۲۱۹۴۲	۰.۲۰۳۱۵	۰.۲۴۱۴۱	۰.۲۹۹۵۲	۰.۳۵۹۷۷
ANN-FIGARCH-N		۰.۰۰۰۹۰	۰.۰۰۲۲۹	۰.۰۰۱۶۷	۰.۰۰۸۱۰۵	۰.۰۰۸۰۰۴۲	۰.۰۰۷۹۷۹	۰.۰۰۷۹۱۶	۰.۰۰۷۸۵۲	۰.۰۰۶۷۸۸	۰.۰۰۳۷۲۳
ANN-FIGARCH-t		۰.۳۰۰۵۶	۰.۳۰۴۹۰	۰.۳۰۹۳۲	۰.۳۱۳۸۲	۰.۳۱۸۳۹	۰.۳۲۳۰۳	۰.۳۲۷۷۵	۰.۳۳۲۵۴	۰.۳۳۷۳۹	۰.۳۴۲۳۱
ANN-FIGARCH-GED		۰.۳۱۳۱۱	۰.۳۱۵۶۰	۰.۳۱۸۰۸	۰.۳۲۰۵۶	۰.۳۲۳۰۳	۰.۳۲۵۴۹	۰.۳۲۷۹۵	۰.۳۳۰۳۹	۰.۳۳۲۸۲	۰.۳۳۵۲۴
FIEGARCH-N		۰.۰۹۱۳۰	۰.۲۵۳۰۶	۰.۲۷۷۲۲	۰.۲۴۲۹۷	۰.۲۱۹۱۹	۰.۲۰۷۱	۰.۲۰۴۳۴	۰.۲۴۲۳۱	۰.۳۰۰۱۸	۰.۳۶۰۲۸
FIEGARCH-t		۰.۱۱۱۹۵	۰.۲۸۹۳۵	۰.۲۸۸۲۷	۰.۲۵۵۲۳	۰.۲۲۸۷۶	۰.۲۳۴۰۲	۰.۲۱۶۹۵	۰.۲۴۵۵۹	۰.۲۹۶۲۵	۰.۳۵۱۶۴
FIEGARCH-GED		۰.۰۸۸۷	۰.۲۸۱۰۶	۰.۲۸۶۳۱	۰.۲۵۲۶۰	۰.۲۲۶۷۲	۰.۲۳۰۸۵	۰.۲۱۳۹۰	۰.۲۴۴۶۳	۰.۲۹۹۸۷	۰.۳۵۳۲۲
ANN-FIEGARCH-N		۰.۱۵۹۲۲	۰.۱۶۰۷۹	۰.۱۶۲۳۸	۰.۱۶۳۹۸	۰.۱۶۵۵۹	۰.۱۶۷۲۲	۰.۱۶۸۸۵	۰.۱۷۰۴۹	۰.۱۷۲۱۵	۰.۱۷۳۸۱
ANN-FIEGARCH-t		۰.۰۳۵۳۳	۰.۰۳۶۹۴	۰.۰۳۸۶۲	۰.۰۴۰۳۷	۰.۰۴۲۱۸	۰.۰۴۴۰۶	۰.۰۴۶۰۰	۰.۰۴۸۰۲	۰.۰۵۰۱۱	۰.۰۵۲۲۶
ANN-FIEGARCH-GED		۰.۰۶۵۹۴	۰.۰۶۵۳۳۳	۰.۰۶۴۷۲	۰.۰۶۴۱۰	۰.۰۶۳۴۸	۰.۰۶۲۸۶	۰.۰۶۲۲۳	۰.۰۶۱۶۰	۰.۰۶۰۹۷	۰.۰۶۰۳۳

جدول (۷) خطای پیش بینی بر اساس معیار MSE

مدل	گام	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
GARCH-N		۰.۰۵۲۵۶	۰.۰۲۱۹۷	۰.۰۲۶۵۳	۰.۰۲۰۳۳	۰.۰۱۶۵۸	۰.۰۱۶۶۹	۰.۱۴۳۱.۰	۰.۰۲۰۳۱	۰.۰۳۱۲۹	۰.۰۴۵۱۳
GARCH-t		۰.۰۱۳۱۷	۰.۰۴۷۰۷	۰.۰۳۹۶۹	۰.۰۲۹۸۲	۰.۰۲۳۸۵	۰.۰۲۲۸۸	۰.۰۱۹۸۱	۰.۰۲۵۷۳	۰.۰۳۸۵۷	۰.۰۵۳۲۴
GARCH-GED		۰.۰۰۷۲۹	۰.۱۰۰۹۶	۰.۰۸۶۶۵	۰.۰۷۰۵۴	۰.۰۵۶۴۵	۰.۰۶۱۷۸	۰.۰۵۳۵۹	۰.۰۶۲۷۷	۰.۰۸۶۰۱	۰.۱۱۸۰۱
ANN-GARCH-N		۰.۰۲۴۶	۰.۰۲۵۳۹	۰.۰۲۶۲۱	۰.۰۲۷۰۷	۰.۰۲۷۹۶	۰.۰۲۸۸۸	۰.۰۲۹۸۳	۰.۰۳۰۸۲	۰.۰۳۱۸۵	۰.۰۳۲۹۱
ANN-GARCH-t		۰.۰۰۱۸۳	۰.۰۰۲۰۱	۰.۰۰۲۲	۰.۰۰۲۴	۰.۰۰۲۶۲	۰.۰۰۲۸۶	۰.۰۰۳۱۱	۰.۰۰۳۳۷	۰.۰۰۳۶۵	۰.۰۰۳۹۵
ANN-GARCH-GED		۰.۰۳۳۸۱	۰.۰۳۵۷۴	۰.۰۳۷۷۹	۰.۰۳۹۹۷	۰.۰۴۲۲۹	۰.۰۴۴۷۵	۰.۰۴۷۳۶	۰.۰۵۰۱۳	۰.۰۵۳۰۶	۰.۰۵۶۱۸

مدل	گام	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
EGARCH-N		۰.۰۰۰۰۹	۰.۰۲۵۴۱	۰.۰۲۸۱۲	۰.۰۲۱۷۸	۰.۰۱۷۶۲	۰.۰۱۸۱۸	۰.۰۱۵۵۹	۰.۰۲۱۱۷	۰.۰۳۱۹۳	۰.۰۴۵۶۹
EGARCH-t		۰.۰۰۳۳۳	۰.۰۸۷۴۴	۰.۰۸۲۰۸	۰.۰۶۵۳۸	۰.۰۵۲۳۶	۰.۰۵۶۰۹	۰.۰۴۸۳۵	۰.۰۶۰۲۵	۰.۰۸۶۲۳	۰.۱۲۱۳۵
EGARCH-GED		۰.۰۰۷۹۴	۰.۰۵۰۱۴	۰.۰۴۰۷۲	۰.۰۳۰۰۸	۰.۰۲۴۶۶	۰.۰۲۴۴۵	۰.۰۲۱۳	۰.۰۲۶۷۳	۰.۰۳۹۵۶	۰.۰۵۴۸۱
ANN-EGARCH-N		۰.۰۲۴۹۹	۰.۰۲۶۴۱	۰.۰۲۷۹	۰.۰۲۹۶۷	۰.۰۳۱۱	۰.۰۳۲۸۱	۰.۰۳۴۶	۰.۰۳۶۴۶	۰.۰۳۸۴	۰.۰۴۰۴۲
ANN-EGARCH-t		۰.۰۱۰۲	۰.۰۳۰۱۹	۰.۰۴۰۱۷	۰.۰۴۰۱۶	۰.۰۶۰۱۴	۰.۰۸۰۱۳	۰.۰۸۰۱۲	۰.۰۹۰۱	۰.۰۷۰۹	۰.۰۶۵۰۸
ANN-EGARCH-GED		۰.۰۰۶۹۱	۰.۰۰۶۹۸	۰.۰۰۷۰۴	۰.۰۰۷۱	۰.۰۰۷۱۷	۰.۰۰۷۲۴	۰.۰۰۷۳۱	۰.۰۰۷۳۸	۰.۰۰۷۴۶	۰.۰۰۷۵۳
FIGARCH-N		۰.۰۶۵۴۷	۰.۰۶۴۴۳	۰.۰۷۷۱۶	۰.۰۵۹۱۷	۰.۰۴۸۲۳	۰.۰۴۸۶۵	۰.۰۴۱۷	۰.۰۵۸۹۷	۰.۰۹۰۷۱	۰.۱۳۰۷۴
FIGARCH-t		۰.۰۰۰۱۱	۰.۰۶۵۶۷	۰.۰۷۷۱۷	۰.۰۵۹۳۳	۰.۰۴۸۲۵	۰.۰۴۸۹۸	۰.۰۴۱۹۸	۰.۰۵۸۷۸	۰.۰۹۰۰۱	۰.۱۲۹۵۵
FIGARCH-GED		۰.۰۰۰۰۴	۰.۰۶۲۲۶	۰.۰۷۵۷۲	۰.۰۵۸۱۸	۰.۰۴۷۳۶	۰.۰۴۸۱۵	۰.۰۴۱۲۷	۰.۰۵۸۲۸	۰.۰۸۹۷۱	۰.۱۲۹۴۴
ANN-FIGARCH-N		۰.۰۱۱۰۱	۰.۰۱۰۴۶	۰.۰۱۰۳۴	۰.۰۱۰۲۱	۰.۰۱۰۴۳	۰.۰۰۳۷۰۹	۰.۰۴۳۰۱	۰.۰۷۸۷۱	۰.۰۴۳۰۵۸	۰.۰۳۸۹۴۵
ANN-FIGARCH-t		۰.۰۰۱۰۱	۰.۰۱۰۴۶	۰.۰۱۰۳۴	۰.۰۱۰۲۱	۰.۰۱۰۰۸	۰.۰۰۲۲۹	۰.۰۰۳۰۱	۰.۰۴۰۷۱	۰.۰۵۰۵۸	۰.۰۸۰۴۵
ANN-FIGARCH-GED		۰.۰۹۸۰۴	۰.۰۹۹۶	۰.۱۰۱۱۷	۰.۱۰۲۷۶	۰.۱۰۴۳۵	۰.۱۰۵۹۴	۰.۱۰۷۵۵	۰.۱۰۹۱۶	۰.۱۱۰۷۷	۰.۱۱۲۳۸
FIEGARCH-N		۰.۰۰۸۳۴	۰.۰۶۴۰۴	۰.۰۷۶۸۵	۰.۰۵۹۰۳	۰.۰۴۸۰۵	۰.۰۴۸۷۱	۰.۰۴۱۷۵	۰.۰۵۸۷۱	۰.۰۹۰۱۱	۰.۱۲۹۸
FIEGARCH-t		۰.۰۱۲۵۳	۰.۰۸۳۷۳	۰.۰۸۳۱	۰.۰۶۵۱۴	۰.۰۵۲۳۳	۰.۰۵۴۷۶	۰.۰۴۷۰۷	۰.۰۶۰۳۱	۰.۰۸۷۷۶	۰.۱۲۳۶۵
FIEGARCH-GED		۰.۰۱۱۸۵	۰.۰۷۹	۰.۰۸۱۹۷	۰.۰۶۳۸۱	۰.۰۵۱۴	۰.۰۵۳۲۹	۰.۰۴۵۷۵	۰.۰۵۹۸۴	۰.۰۸۱۱۳	۰.۱۲۴۷۶
ANN-FIEGARCH-N		۰.۰۲۵۲۵	۰.۰۲۵۸۵	۰.۰۲۶۳۷	۰.۰۲۶۸۹	۰.۰۲۷۴۲	۰.۰۲۷۹۶	۰.۰۲۸۵۱	۰.۰۲۹۰۷	۰.۰۲۹۶۳	۰.۰۳۰۲۱
ANN-FIEGARCH-t		۰.۰۰۱۲۵	۰.۰۰۱۳۶	۰.۰۰۱۴۹	۰.۰۰۱۶۳	۰.۰۰۱۷۸	۰.۰۰۱۹۴	۰.۰۰۲۱۲	۰.۰۰۲۳۱	۰.۰۰۲۵۱	۰.۰۰۰۷۳
ANN-FIEGARCH-GED		۰.۰۰۴۳۵	۰.۰۰۴۲۷	۰.۰۰۴۱۹	۰.۰۰۴۱۱	۰.۰۰۴۰۳	۰.۰۰۳۹۵	۰.۰۰۳۸۷	۰.۰۰۳۹۴	۰.۰۰۱۲۷	۰.۰۰۰۱۲

جدول (۸) خطای پیش‌بینی بر اساس معیار MAE

مدل	گام	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
GARCH-N		۰.۰۱۱۱۷	۰.۱۰۵۱۵	۰.۱۳۳۰۳	۰.۱۱۰۱۳	۰.۰۹۶۱۲	۰.۱۰۱۹۷	۰.۰۸۷۸	۰.۱۰۸۰۳	۰.۱۳۴۳۰	۰.۱۶۲۱۳
GARCH-t		۰.۱۱۴۷۴	۰.۱۹۹۶۴	۰.۱۸۵۷۰	۰.۱۴۲۷۶	۰.۱۱۴۲۸	۰.۱۱۷۵۹	۰.۱۰۶۰۹	۰.۱۲۵۲۳	۰.۱۵۳۰۸	۰.۱۸۰۸۲
GARCH-GED		۰.۰۸۵۴	۰.۲۶۳۲	۰.۲۵۵۸	۰.۲۲۹۱۴	۰.۱۸۴۸۱	۰.۲۰۳۵۹	۰.۱۸۴۰۳	۰.۲۰۵۵۱	۰.۲۴۰۶۸	۰.۲۸۰۳۱
ANN-GARCH-N		۰.۱۵۶۸۴	۰.۱۵۹۳۰	۰.۱۶۱۸۶	۰.۱۶۴۴۳	۰.۱۶۷۰۵	۰.۱۶۹۷	۰.۱۷۲۴	۰.۱۷۵۱۳	۰.۱۷۷۹۱	۰.۱۸۰۷۲
ANN-GARCH-t		۰.۰۴۲۷۱	۰.۰۴۴۷۱	۰.۰۴۶۷۶	۰.۰۴۸۸۱	۰.۰۵۰۸۹	۰.۰۵۳	۰.۰۵۵۱۲	۰.۰۵۷۲۱	۰.۰۵۹۴۴	۰.۰۶۱۶۳
ANN-GARCH-GED		۰.۱۸۳۸۱	۰.۱۸۸۹۹	۰.۱۹۴۲۲	۰.۱۹۹۵۸	۰.۲۰۵۰۷	۰.۲۱۰۷	۰.۲۱۶۴۶	۰.۲۲۲۳۱	۰.۲۲۸۴	۰.۲۳۴۵
EGARCH-N		۰.۰۰۹۶۷	۰.۱۱۷۴۴	۰.۱۳۹۳۱	۰.۱۱۷۷۱	۰.۱۰۰۳۱	۰.۱۰۷۷۳	۰.۰۹۳۴۲	۰.۱۱۲۴۳	۰.۱۳۸۱	۰.۱۶۵۴۶
EGARCH-t		۰.۰۰۵۷۷۱	۰.۲۳۵۹۰	۰.۲۴۶۳۰	۰.۲۱۵۶۵	۰.۱۷۵۹۵	۰.۱۹۲۱۹	۰.۱۷۰۹۴	۰.۱۹۶۹۳	۰.۲۳۵۴	۰.۲۷۷۶۰
EGARCH-GED		۰.۰۸۹۰۸	۰.۱۹۶۴۸	۰.۱۸۰۳	۰.۱۴۳۲۵	۰.۱۱۶۶۶	۰.۱۲۲۷۳	۰.۱۱۲۱۷	۰.۱۲۹۹۴	۰.۱۵۷۴۱	۰.۱۸۵۴۹
ANN-EGARCH-N		۰.۱۵۸۰۸	۰.۱۶۲۴۵	۰.۰۶۶۸۰	۰.۱۷۱۳۷	۰.۱۷۵۹	۰.۱۸۰۴۸	۰.۱۸۵۱۱	۰.۱۸۹۷۰	۰.۱۹۴۴۹	۰.۱۹۹۲۵
ANN-EGARCH-t		۰.۰۱۴۲۹	۰.۰۱۳۶۹	۰.۰۱۳۰۷	۰.۰۱۲۴۴	۰.۰۱۱۷۸	۰.۰۱۱۱۱	۰.۰۱۰۴۳	۰.۰۰۹۷۲	۰.۰۰۸۹۹	۰.۰۰۸۲۵
ANN-EGARCH-GED		۰.۰۸۳۱۴	۰.۰۸۳۵۱	۰.۰۸۳۹	۰.۰۸۴۲۰	۰.۰۸۴۶۲	۰.۰۸۵۰۸	۰.۰۸۵۴۱	۰.۰۸۵۹۱	۰.۰۸۶۳۰	۰.۰۸۶۷۰
FIGARCH-N		۰.۰۰۰۲۷	۰.۱۷۹۶۲	۰.۲۲۶۵۰	۰.۱۸۷۹۰	۰.۱۶۳۷۲	۰.۱۷۳۹۹	۰.۱۴۹۵۸	۰.۱۸۳۸۰	۰.۲۲۸۶۱	۰.۲۷۵۸

مدل	گام	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
FIGARCH-t		۰,۰۰۲۷۳	۰,۱۸۲۵۶	۰,۲۲۷۲۱	۰,۱۸۹۴۶	۰,۱۶۴۱۲	۰,۱۷۵	۰,۱۵۰۱۳	۰,۱۸۳۸۰	۰,۲۲۸۲۱	۰,۲۷۵۰۱
FIGARCH-GED		۰,۰۳۸۳۱	۰,۱۹۴۴۲	۰,۲۳۶۴۱	۰,۱۹۵۸۹	۰,۱۶۹۵۳	۰,۱۷۹۳۱	۰,۱۵۳۷۰	۰,۱۸۷۱۵	۰,۲۳۱۲۶	۰,۲۷۷۹۱
ANN-FIGARCH-N		۰,۱۰۲۹	۰,۱۰۲۲۸	۰,۱۰۱۶۷	۰,۱۰۱۰۴	۰,۱۰۰۴۱	۰,۰۹۹۷۷	۰,۰۹۹۱۳	۰,۰۹۸۴۱	۰,۰۹۷۸۱	۰,۰۹۷۱۶
ANN-FIGARCH-t		۰,۳۰۰۵۶	۰,۳۰۴۸۱	۰,۳۰۹۲۴	۰,۳۱۳۶۶	۰,۳۱۸۱۴	۰,۳۲۲۶۰	۰,۳۲۷۲۱	۰,۳۳۱۸۱	۰,۳۳۶۵	۰,۳۴۱۲۰
ANN-FIGARCH-GED		۰,۳۱۳۱۱	۰,۳۱۵۵	۰,۳۱۸۰۵	۰,۳۲۰۵۱	۰,۳۲۲۹	۰,۳۲۵۳	۰,۳۲۷۸	۰,۳۳۰۲	۰,۳۳۲۵	۰,۳۳۴۹
FIEGARCH-N		۰,۰۹۱۳	۰,۲۱۸۶۷	۰,۲۵۲۴۱	۰,۲۰۸۰۳	۰,۱۷۹۲۲	۰,۱۸۷۳۰	۰,۱۶۰۶۵	۰,۱۹۳۲۲	۰,۲۳۶۶۱	۰,۲۸۲۷
FIEGARCH-t		۰,۱۱۱۹۵	۰,۲۵۲۷۱	۰,۲۶۳۸۱	۰,۲۲۴۴۰	۰,۱۸۶۱۹	۰,۱۹۸۲۷	۰,۱۷۴۲۳	۰,۲۰۱۳۵	۰,۲۴۰۵۰	۰,۲۸۳۳
FIEGARCH-GED		۰,۱۰۸۸۷	۰,۲۴۵۵	۰,۲۶۲۵	۰,۲۲۱۰۵	۰,۱۸۵۲۵	۰,۱۹۶۱۲	۰,۱۷۱۳۲	۰,۱۹۹۶۷	۰,۲۳۹۷	۰,۲۸۳۲
ANN-FIEGARCH-N		۰,۱۵۹۲۲	۰,۱۶۰۷۸	۰,۱۶۳۳۶	۰,۱۶۳۹۴	۰,۱۶۵۵	۰,۱۶۷۱۳	۰,۱۶۸۷	۰,۱۷۰۳۴	۰,۱۷۱۹۵	۰,۱۷۳۵
ANN-FIEGARCH-t		۰,۰۰۵۳۳	۰,۰۰۶۹۱	۰,۰۰۸۵۳	۰,۰۰۴۰۲	۰,۰۰۴۱۹۱	۰,۰۰۳۶۷	۰,۰۰۵۴۷	۰,۰۰۷۳۲	۰,۰۰۹۲۲	۰,۰۰۱۱۷
ANN-FIEGARCH-GED		۰,۰۰۰۹۴	۰,۰۰۵۳۳	۰,۰۰۶۴۷۱	۰,۰۰۶۴۰۹	۰,۰۰۶۳۴۶	۰,۰۰۶۲۸۲	۰,۰۰۶۲۱۸	۰,۰۰۶۱۵۳	۰,۰۰۶۰۸۸	۰,۰۰۶۰۲۲

پس از تخمین مدل های مورد نظر و پیش بینی ۱۰ روز آتی (گام) بازدهی شاخص کل، برای مقایسه قدرت پیش بینی مدل های مورد نظر از معیار های مجذور میانگین مربع خطا RMSE میانگین مربع خطا MSE و میانگین قدر مطلق خطا MAE به صورت گام به گام استفاده شد. همانطور که از جداول فوق مشاهده می شود، میزان خطای این مدل ها به صورت تفکیک شده آورده شده است. برای هر یک از سه معیار مذکور، میزان خطا در گام های پیش بینی شده نسبت به بقیه گام ها برای بیشتر مدل ها کمتر است. در جدول (۶) که نشان دهنده میزان خطا بر اساس معیار RMSE است در گام های ابتدایی مدل های، FIGARCH-N، FIGARCH-t و مدل های ترکیبی ANN-EGARCH-t، ANN-FIGARCH-N، ANN-، FIEGARCH-t دارای کمترین میزان خطای پیش بینی است با افزایش میزان گام ها میزان دقت پیش بینی این مدل ها کاسته می شود. دقت مدل ANN-FIEGARCH-t نسبت به بقیه مدل ها به میزان کمتری کاهش می یابد. در جدول (۷) بر اساس شاخص MSE مدل های FIGARCH-t، FIGARCH-GED، ANN-GARCH-t دارای کمترین خطای پیش بینی است بنابراین این مدل بر اساس این شاخص به عنوان مدل برگزیده انتخاب می گردد. در جدول (۸) نیز مدل های ANN-EGARCH-t و ANN-FIEGARCH-t این ویژگی را دارند. در مجموع نتایج نشان دهنده این است که مدل های ترکیبی دارای خطای کمتری نسبت به بقیه مدل ها است و دقت پیش بینی با افزایش تعداد گام ها کاهش یافته است. همچنین با توجه به ویژگی عدم نرمال بودن بازدهی این شاخص که در جداول فوق نمایش داده شد، می توان بیان نمود که مدل هایی که دارای توزیع t و GED بودند به صورت دقیق تری قادر به پیش بینی نوسانات این شاخص هستند.

انتخاب مدل بهینه

با توجه به مطالب بیان شده در بخش‌های قبلی مدل ANN-FIEGARCH-t به عنوان مدل بهینه که توانایی بالایی در پیش‌بینی نوسان این شاخص دارد برگزیده شد. انتخاب این مدل بر اساس توانایی آن در دقت پیش‌بینی در هر سه معیار دقت خطا است. بنابراین در این قسمت مدل ریاضی این مدل و ضرائب آن توضیح داده می‌شود. ساختار ریاضی این مدل و ضرائب آن در قسمت زیر آورده شده است:

$$\ln(\sigma_t^2) = 0.802 + 0.934(L)^{-1}(1-L)^{0.504}[1 + 0.260(L)](0.052 \frac{\varepsilon_{t-1}}{|\sigma_{t-1}|} + 0.488[\frac{|\varepsilon_{t-1}|}{|\sigma_{t-1}|} - E \frac{|\varepsilon_{t-1}|}{|\sigma_{t-1}|}]) - 0.001v_{oil} + 0.033v_{dollar}$$


(۱.۳۹) (۱۷۲.۵) (۱.۸۱) (-۱۴.۶۲) (۱.۴۱) (۷.۹۹) (-۰.۲۵) (۰.۸۴)

در این مدل معنادار بودن اثرات میانگین نشان‌دهنده این است که بازدهی هر دوره به صورت ضریبی از بازدهی و شوک‌های دوره قبل است و در قسمت واریانس شرطی میزان ضریب ARCH که در معادله به میزان ۰,۲۶۰ است به صورت قابل ملاحظه ای معنی دار است که نشان دهنده وجود اثرات کوتاه مدت در بازدهی نوسان شاخص بورس است. همچنین وجود اثرات GARCH در این مدل که ضریب آن به صورت ۰,۹۳۴ نمایش داده می‌شود به دلیل وجود معنی داری این در ساختار تایید می‌شود. در این مدل اثرات شوک‌های نامتقارن که به صورت EGARCH نمایش داده می‌شود نیز با ضرائب ۰,۵۸۸ و ۰,۰۵۲ تایید می‌گردد. وجود حافظه بلندمدت در این مدل نیز که مقدار آن با ۰,۵۰۴ نمایش داده شده است تایید می‌شود. میرا شدن این حافظه در بلند مدت به دلیل آن است که این مقدار در دامنه $-0.5 < d < 0.5$ نیست مورد تایید قرار نمی‌گیرد. در واقع این به معنای پایداری شوک‌های وارد شده بر این شاخص در بلند مدت است. عدم معنی داری ضرائب دو متغیر نفت و دلار که به صورت واریانس شرطی به این مدل اضافه شده نشان دهنده آن است که این متغیرها در بلند مدت تأثیری بر روی شاخص مورد نظر ندارد و امکان آنکه قیمت نفت و دلار بتواند تأثیر خود را در زمان بر روی بازدهی شاخص بورس حفظ کند وجود ندارد. اما این به معنای عدم تأثیرگذاری نفت بر شاخص اصلی بورس نیست همانگونه که در سایر مدل‌ها نشان داده شد نفت تأثیرگذاری خود را بر روی شاخص اصلی بورس در کوتاه مدت دارد، میتوان این نتیجه را گرفت هرچه شوک‌های قیمتی نفت بر نوسانات شاخص اصلی بورس تأثیری مستقیم حداقل در کوتاه مدت دارد.

پیش‌بینی بازده شاخص

پس از انجام پیش‌بینی و انتخاب مدل بهینه ANN-FIEGARCH-t، برای درک پیش‌بینی به گونه شهودی‌تر و اینکه مقادیر پیش‌بینی شده به مقادیر واقعی چه میزان نزدیک است، نمودار آن برای مقادیر واقعی و پیش‌بینی

شده به صورت زبر آورده شده است. همانگونه که مشاهده می شود تفاوت مقادیر پیش بینی شده در این نمودار به مقادیر واقعی مشخص است.



نمودار (۱) مقایسه پیش بینی مدل ترکیبی ANN-FIEGARCH-t با مقادیر واقعی

۵- نتیجه گیری

اندازه گیری، پیش بینی و مدل سازی نوسانات قیمت دارایی های مختلف مالی، به عنوان مثال سهام، کالاها و نرخ های ارز، یک موضوع به طور گسترده مورد مطالعه در تحقیقات مالی است. در این مقاله، مدل های خانواده ترکیبی ANN-GARCH (X)-ARMA برای پیش بینی نوسانات بازار سهام مورد بررسی قرار گرفته است. سپس مدل ترکیبی از خانواده GARCH و شبکه عصبی مصنوعی جهت پیش بینی نوسان شاخص سهام با در نظر گرفتن حافظه بلندمدت با سه توزیع نرمال، t و GED برآورده شد. در ادامه بر اساس معیارهای RMSE، MSE و MAE به مقایسه مدل های ترکیبی با مدل های خانواده GARCH پرداخته شد و نتایج حاصل از این تحقیق این مطلب را تصدیق نمود که مدل های ترکیبی ANN-EGARCH با توزیع t و GED و مدل های ترکیبی ANN-FIEGARCH با توزیع نرمال و مدل ANN-FIEGARCH با توزیع نرمال، t و GED دارای کمترین میزان خطا بودند. علاوه بر این مدل های ANN-GARCH با توزیع t نیز مدل های مناسبی تشخیص داده شدند. در واقع عدم وجود نرمال بودن در این مدل ها باعث شده که توزیع های t و GED نسبت به توزیع نرمال توانایی بهتری در پیش بینی و حرکت بازدهی شاخص بورس دارند. همچنین وجود حافظه بلند مدت در این مدل ها باعث شده که مدل های دارای این ویژگی، قادر به توضیح حرکات نوسان شاخص بورس باشند. نتایج حاصل شده نشان دهنده

این مطلب است که مدل‌های ترکیبی خانواده GARCH دارای حافظه بلندمدت با شبکه عصبی به طور خاص ANN-FIEGARCH-t در پیش‌بینی نوسان بازده سهام کارآمدتر و دارای خطای پیش‌بینی کمتری هستند. در این پژوهش نوسانات بازار نفت به عنوان عوامل مهم و تاثیرگذار در بازار سهام معرفی گردید، بنابراین سرمایه‌گذاران بازارهای مالی می‌توانند با در نظر گرفتن این نوسانات به بهینه سازی سبدپورتفوی خود (به نحوی که کمترین آسیب را از نوسانات بازارهای نفت دریافت نمایند) بپردازند. به طور خلاصه، مشخص شد که مدل‌های ANN می‌توانند عملکرد پیش‌بینی مدل خانواده GARCH را در بازار سهام اصلی نمایش دهند و نشان داده شد که نتایج قابل اتکایی ارائه می‌دهند. در نهایت با توجه به اینکه پیش‌بینی تغییرپذیری یا نوسان در مدیریت ریسک، ارزش‌گذاری سبد سرمایه، قیمت‌گذاری مشتقات و ... کاربردهای فراوانی دارد؛ و از دیدگاه معامله‌گران بازار مشتقات، درک نوسان پذیری، پیش‌بینی دقیق آن و حفاظت از سبد دارایی‌های در مقابل هزینه‌هایی که این متغیر به ارزش کل تحمیل می‌کند، از اهمیت دوچندانی برخوردار است، استفاده از چنین ساختاری که تقریباً تمامی عوامل اثرگذار (اخبار سیاسی، شوک‌های داخلی و خارجی و ...) در این شاخص‌ها را در نظر می‌گیرد، می‌تواند مفید و کاربردی باشد.

فهرست منابع

- * جباری حسین، نقدی نریمان. رابطه بین ساختار سرمایه و چرخه عمر شرکت. پژوهش‌های حسابداری مالی و حسابرسی، تابستان ۱۳۹۵، دوره ۸، شماره ۳۰، ۱۳۹-۱۶۲
- * سعیدی حسین، محمدی شاپور. پیش‌بینی نوسانات بازده بازار با استفاده از مدل‌های ترکیبی گارچ شبکه عصبی. فصلنامه بورس اوراق بهادار، زمستان ۱۳۹۰، دوره ۴، شماره ۱۶، ۱۵۳-۱۷۴.
- * طحاری مهرجردی محمدحسین، فاضل یزدی علی، زارعی محمودآبادی محمد. کاربرد تحلیل نا پارامتریک بازه‌ای و پنجره‌ای به عنوان مکملی برای ارزیابی کارایی مالی (مطالعه موردی: بانک‌های پذیرفته‌شده در بورس اوراق بهادار تهران). دانش مالی تحلیل اوراق بهادار، پاییز ۱۳۹۲، دوره ۶، شماره ۳، ۲۷-۴۴
- * کریمی، محمد شریف، امام وردی، قدرت اله، دباغی، نیشتمان. (۱۳۹۲). ارزیابی و شناسایی مناسب‌ترین گزینه سرمایه‌گذاری دارایی و مالی در ایران (در بازه زمانی ۱۳۸۹-۱۳۸۰). اقتصاد مالی، زمستان ۱۳۹۲، دوره ۷، شماره ۲۵، ۱۷۷-۲۰۷
- * Anwar, S., & Mikami, Y. (2011). Comparing accuracy performance of ANN, MLR, and GARCH model in predicting time deposit return of Islamic bank. *International Journal of Trade, Economics and Finance*, 2(1), 44
- * Bildirici, M., & Ersin, Ö. Ö. (2009). Improving forecasts of GARCH family models with the artificial neural networks: An application to the daily returns in Istanbul Stock Exchange. *Expert Systems with Applications*, 36(4), 7355-7362.
- * Kristjanpoller, W., & Hernández, E. Volatility of main metals forecasted by a hybrid ANN-GARCH model with regressors. *Expert Systems with Applications*, 2017, 84, 290-300.
- * Kristjanpoller, W., & Minutolo, M. C. A hybrid volatility forecasting framework integrating GARCH, artificial neural network, technical analysis and principal components analysis. *Expert Systems with Applications*, 2018, 109, 1-11.

- * Lahmiri, S., & Boukadoum, M. An Ensemble System Based on Hybrid EGARCH-ANN with Different Distributional Assumptions to Predict S&P 500 Intraday Volatility. *Fluctuation and Noise Letters*, 2015, 14(01), 1550001.
- * Lu, X., Que, D., & Cao, G. Volatility forecast based on the hybrid artificial neural network and GARCH-type models. *Procedia Computer Science*, 2016, 91, 1044-1049.
- * Markowitz, H. Portfolio selection. *The journal of finance*, 1952, 7(1), 77-91.
- * Monfared, S. A., & Enke, D. Volatility forecasting using a hybrid GJR-GARCH neural network model. *Procedia Computer Science*, 2014, 36, 246-253
- * Siddiqui, M. U., Abbas, A., AbdurRehman, S. M., Jawed, A., & Rafi, M. Comparison of garch model and artificial neural network for mutual fund's growth prediction. In *Computing, Mathematics and Engineering Technologies (iCoMET)*, 2018 International Conference on, 2018, (pp. 1-7).
- * Güreşen, E., & Kayakutlu, G. (2008, October). Forecasting stock exchange movements using artificial neural network models and hybrid models. In *International Conference on Intelligent Information Processing* (pp. 129-137). Springer, Boston, MA.
- * Fatima, S. (2017). Comparison of Asymmetric Garch models with Artificial Neural Network For Stock prediction A case study. *Journal of Engoneering and Applied Sience*, 36(1)
- * Lahmiri, S. (2017). Modeling and predicting historical volatility in exchange rate markets. *Physica A: Statistical Mechanics and its Applications*, 471, 387-395.
- * Wang, Y. H. (2009). Nonlinear neural network forecasting model for stock index option price: Hybrid GJR-GARCH approach. *Expert Systems with Applications*, 36(1), 564-570.
- * Lahmiri, S., & Boukadoum, M. (2015). An Ensemble System Based on Hybrid EGARCH-ANN with Different Distributional Assumptions to Predict S&P 500 Intraday Volatility. *Fluctuation and Noise Letters*, 14(01), 1550001.
- * Monfared, S. A., & Enke, D. (2014). Volatility forecasting using a hybrid GJR-GARCH neural network model. *Procedia Computer Science*, 36, 246-253.
- * Kristjanpoller, W., Fadic, A., & Minutolo, M. C. (2014). Volatility forecast using hybrid neural network models. *Expert Systems with Applications*, 41(5), 2437-2442.
- * Wang, G. (2006). A note on unit root tests with heavy-tailed GARCH errors. *Statistics & probability letters*, 76(10), 1075-1079
- * Wang, Y. H. (2009). Nonlinear neural network forecasting model for stock index option price: Hybrid GJR-GARCH approach. *Expert Systems with Applications*, 36(1), 564-570

یادداشت‌ها

- ¹. Derivative Contract.
- ². Markowitz
- ³. Autoregressive Conditional Heteroscedasticity Models.
- ⁴. Generalized Autoregressive Conditional Heteroscedasticity.
- ⁵. The Exponential GARCH.
- ⁶. Over-Differencing.
- ⁷. Fractional Integratin.
- ⁸. Fractional Integratin GARCH.
- ⁹. Fractional Integratin Exponential GARCH.
- ¹⁰. Tehran Price Index
- ¹¹. Kristjanpoller & Minutolo
- ¹². Bitcoin.
- ¹³. Siddiqui et all

- ¹⁴.Kristjanpoller, W., & Hernández
- ¹⁵.Fatima
- ¹⁶.Asymetric Garch
- ¹⁷.Root Mean Square Error
- ¹⁸.Lahmiri
- ¹⁹.Generalized Error Distribution
- ²⁰.Mean Absolute Error
- ²¹.Mean Squared Error
- ²².Lu et all
- ²³.S. Lahmiri & M. Boukadoum
- ²⁴.Back Propagation
- ²⁵.Monfared&Enke.
- ²⁶.Glosten-Jagannathan-Runkle GARCH
- ²⁷.Radial Basis Function
- ²⁸. Kristjanpoller el all
- ²⁹Anwar & Mikami
- ³⁰.Wang
- ³¹.Mean Absolute Percentage Error
- ³².Güreşen & Kayakutlu
- ³³.Bildirici & Ersin
- ³⁴.R.F. Engle.
- ³⁵.T. Bollerslev.
- ³⁶.Integrated GARCH.
- ³⁷.Artificial Neural Network.
- ³⁸.Autoregressive Moving Average.
- ³⁹.Autoregressive Integrated Moving Average.
- ⁴⁰.Box –Jenkins.
- ⁴¹.Autocorrelation.
- ⁴².Partial Autocorrelation.
- ⁴³.Akaike Information Criterion.
- ⁴⁴.Schwarz Bayesian Information Criterion.
- ⁴⁵.Hannan–Quinn Information Criterion.
- ⁴⁶.Volatility
- ⁴⁷.Nelson.
- ⁴⁸.Ballie et al.
- ⁴⁹.Mikkelsen.
- ⁵⁰.Rescaled range.
- ⁵¹.Geweke and Porter-Hudak.
- ⁵².Input Layer.
- ⁵³.Hidden Layer.
- ⁵⁴.Output Layer.
- ⁵⁵.Multi-Layer Perceptron.
- ⁵⁶.Bias.
- ⁵⁷.Tensor.
- ⁵⁸.Supervised Learning.
- ⁵⁹.Unsupervised Learning.
- ⁶⁰.Back-propagation
- ⁶¹.Probability Density Function
- ⁶².Tail
- ⁶³.Eptokurtic
- ⁶⁴.Mesokurtic
- ⁶⁵.Platykurtic
- ⁶⁶.Prespetron.
- ⁶⁷.Jarque-Bera.

طراحی مدلی جهت پیش بینی بازده شاخص بورس (با تاکید بر مدل های ترکیبی ...)/ رضا نجارزاده، مهدی ذوالفقاری و صمد غلامی

⁶⁸. augmented Dicky Fuller.

⁶⁹. Phillips-Perron.

⁷⁰. Kwiatkowski-Phillips-Schmidt-Shin.

⁷¹. LM ARCH Test.

⁷². Leverage effect.