



طراحی مدلی جهت پیش بینی بازده بیت کوین (با تاکید بر مدل های ترکیبی شبکه عصبی کانولوشنی و بازگشتی و مدل های با حافظه بلندمدت)

محمدجواد بختیاران^۱

مهدی ذوالفقاری^۲

تاریخ دریافت مقاله: ۹۹/۰۸/۱۸ تاریخ پذیرش مقاله: ۹۹/۱۰/۲۴

چکیده

پژوهش حاضر به معرفی مدل هایی از ترکیب خانواده GARCH با حافظه بلندمدت و شبکه ترکیبی عصبی کانولوشنی و بازگشتی، جهت مدل سازی و پیش بینی بازدهی روزانه بیت کوین طی دوره ۱۳۹۸-۱۳۹۲ می پردازد. وجود ویژگی حافظه بلندمدت در واریانس شرطی بازدهی بیت کوین موجب شده تا علاوه بر مدل های دارای حافظه کوتاه مدت GARCH و EGARCH در این پژوهش از مدل های FIGARCH و FIEGARCH که دارای ویژگی حافظه بلندمدت هستند؛ استفاده گردد. علاوه بر بکارگیری مدل های حافظه کوتاه مدت، با توجه به کارایی بهتر مدل های ترکیبی (در مقایسه با مدل های فردی) در پیش بینی داده های مالی، در این مطالعه، تمامی مدل های خانواده GARCH (اعم از کوتاه مدت و بلندمدت) با شبکه ترکیبی عصبی کانولوشنی و بازگشتی ترکیب و با استفاده از مدل های ترکیبی حاصل شده، بازده بیت کوین برای ۱۰ روز آینده به صورت گام به گام پیش بینی و دقت آن براساس معیارهای ارزیابی مورد بررسی قرار گرفت. یافته های پژوهش نشان داد که مدل ترکیبی FIEGARCH- شبکه عصبی با توزیع تی- استیودنت در پیش بینی بازده بیت کوین کارآمدتر و دارای خطای پیش بینی کمتری نسبت به سایر مدل های رقیب است.

کلمات کلیدی

بیت کوین، پیش بینی، خانواده GARCH، شبکه ترکیبی عصبی کانولوشنی و بازگشتی، مدل ترکیبی

۱- گروه علوم اقتصادی، دانشکده مدیریت و اقتصاد، دانشگاه تربیت مدرس، تهران، ایران m.bakhtiaran@modares.ac.ir

۲- گروه علوم اقتصادی، دانشکده مدیریت و اقتصاد، دانشگاه تربیت مدرس، تهران، ایران. (نویسنده مسئول) m.zolfaghari@modares.ac.ir

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 رمزارزها نقش ویژه‌ای در تخصیص منابع سرمایه‌ای به بخش‌های مولد از طریق جذب منابع خرد و سرگردان را دارد. ساختار و چارچوب شفاف بازار بیت‌کوین^۱ در قیمت‌گذاری و انتشار اطلاعات مربوط به ارزش آن، باعث شناسایی این بازارها به‌عنوان نماینده وضعیت بخش پولی اقتصاد جهانی 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 نامانای 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 مدل‌های ناپارامتری همانند یادگیری عمیق می‌تواند به‌دقت سیستم پیش‌بینی کننده بیفزاید.

در سایر مطالعات انجام شده در این حوزه با در نظر گرفتن مدل‌های مرسوم خانواده GARCH و ترکیب آن با شبکه عصبی مصنوعی، سعی در پیش‌بینی نوسانات شاخص‌های مورد مطالعه شده است. این در حالی است که عدم لحاظ حافظه بلندمدت در مدل‌های مورد بررسی باعث کاهش توانایی مدل‌ها در پیش‌بینی سری‌های زمانی می‌گردد. با توجه به این مهم، در مقاله حاضر سعی بر آن شده که در مدل‌های ترکیبی علاوه

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

برمدل‌های حافظه کوتاه‌مدت از مدل‌هایی که نشان دهنده حافظه بلندمدت هستند استفاده گردد و کاستی یافته‌های قبلی در این حوزه را بکاهد و دقت مدل‌ها را در پیش‌بینی نوسانات افزایش دهد.

بنابراین نوآوری‌های مقاله مذکور به ترتیب ذیل می‌باشد:

- توسعه ادبیات تحقیق در حوزه بازارهای مالی جدید (رمزارها نظیر بیت کوین) در مطالعات داخلی

- توسعه مدل‌های حافظه بلندمدت FIGARCH و FIEGARCH

- ارائه مدل ترکیبی خانواده GARCH - شبکه ترکیبی عصبی کانولوشنی و بازگشتی

- لحاظ متغیرهای کنترلی قیمت طلا و قیمت نفت در مدل ترکیبی

فرضیات پژوهش

با توجه به اینکه سوالات این مقاله پیمایشی می‌باشد لذا پاسخ به سوالات در جریان تحقیق حاصل شده است.

سوالات پژوهش

سوال اول پژوهش این است که پیش‌بینی بیت کوین با استفاده از مدل ترکیبی چگونه است؟

و سوال دوم نیز این است که میزان دقت روش ترکیبی چگونه است؟

ادبیات و مبانی نظری پژوهش

دنیای تکنولوژی با سریعترین سرعت خود در عصر جدید بر روی زندگی تک تک انسان‌ها تغییرات شگرف و عمیقی ایجاد کرده است. یکی از تغییرات ایجاد شده در حوزه مالی و امنیت، معرفی ابزار پرداخت جدید مالی (از خانواده پول) با عنوان بیت کوین است. بیت کوین به عنوان اولین ارز رمزنگاری شده بر بستر بسیار امن و شفاف خود یعنی بلاک چین عرضه شده و در این راه توانسته ارزش خود را در حدود کمتر از ۱۲ سال از یک دلار به حدود ۳۰ هزار دلار برساند و با نوسانات بسیار خود به راهش ادامه دهد. گلاسر و همکاران^{۱۰} (۲۰۱۴) در خصوص جایگاه بیت کوین به عنوان یک ارز به بررسی توانایی آن به عنوان وسیله‌ای برای دادوستد به مطالعه پرداخته‌اند. نتایج این مطالعه نشان می‌دهد که بیت کوین به نسبت نقد است، به نحوی که امکان تبادل آن با سایر ارزهای رایج وجود دارد. ولیکن به دلیل کمیاب بودن، دارای محدودیت‌هایی همچون سایر کالا می‌باشد. بوهم و همکاران^{۱۱} (۲۰۱۵) دریافته‌اند که آن دسته از تراکنش‌های مالی که نیاز به مدت زمانی بیش از یک ساعت دارند، امکان نقدشوندگی آنها به شدت کاهش می‌یابد، که بیت کوین نیز بر بستر بسیار سریعی قابلیت نقل و انتقال دارد. گلاسر و همکاران (۲۰۱۴) دریافته‌اند که اکثر استفاده‌کنندگان، با بیت کوین سرمایه‌گذاری شده خود بجای آنکه به عنوان وسیله‌ای برای پرداخت استفاده نمایند، به عنوان دارایی‌های

سوداگرانه برخورد می‌کنند. بیت‌کوین نیز مانند طلا ارزش خود را از کمیابی و دشواری استخراج خود کسب می‌کنند و هیچکدام دارای یک ملیت خاص نیستند و تحت کنترل هیچ دولت و حکومتی نیستند. هر دو توسط مجموعه‌های خاصی استخراج می‌گردند. در دوره زمانی خاصی، طلا به عنوان ابزاری برای مبادله استفاده می‌شد، اما به مرور زمان و به علت مشکلات نقدشوندگی کنار گذاشته شد. اوکلی و همکاران^{۱۲} (۲۰۱۸) معتقد هستند که بیت‌کوین شبیه به دلار است. آنها معتقد هستند که هر دوی بیت‌کوین و طلا دارای ارزش ذاتی محدود یا فاقد ارزش ذاتی هستند و در ابتدا از آنها به عنوان وسیله‌ای برای مبادله استفاده می‌گردد. البته تفاوت اصلی این است که دلار از سوی دولتی که مردم بدان اعتماد دارند، پشتیبانی می‌شود، درحالی‌که بیت‌کوین یک پول غیردولتی است که توسط بخش خصوصی معرفی شده است. در نتیجه فرآیند عرضه، نظارت و کنترل دو دارایی متفاوت است، اما مقایسه آنها با یکدیگر بسیار جالب است و با مقایسه آنها می‌توان به توانایی‌های پولی آنها پی‌برد. تعریف بیت‌کوین دشوار است، در نتیجه تجزیه و تحلیل واکنش آن در مقابل متغیرهایی که سبب واکنش قیمت طلا و دلار نسبت به همان متغیرها می‌شود، می‌تواند اطلاعات بسیاری را به همراه داشته‌باشد. چارچوب مدل‌های واریانس ناهمسانی شرطی اتورگرسیون (گارچ) می‌تواند مولفه‌ها و عواملی را که در دنیای اقتصادی بر بیت‌کوین اثرگذار خواهد بود، مشخص کند. کاپی و همکاران^{۱۳} (۲۰۰۵) دریافتند که ممکن است بیت‌کوین قابلیت‌های بالقوه‌ای در مدیریت ریسک همچون طلا در برابر دلار داشته‌باشد. اگرچه گستره این توانایی به سطوح نوسانات پیشین بیت‌کوین و دلار بستگی دارد. دایربرگ^{۱۴} (۲۰۱۶) دریافت که عموماً به نظر می‌رسد زمانی که شوک‌های مثبت وجود دارد، به استثنای نرخ ارز دلار/یورو، نوسان بازده بیت‌کوین کاهش می‌یابد. این موضوع بیانگر آن است که شاید بیت‌کوین برای سرمایه‌گذاران ریسک‌گریز مناسب‌تر باشد. اما این نتایج مشابه نتیجه مطالعات تولی و لوسی^{۱۵} (۲۰۰۷) نیست. تولی و لوسی (۲۰۰۷) معتقد بودند که واریانس بیت‌کوین توسط مولفه‌های خارجی تعیین می‌گردد و به عوامل درون‌زا مانند طلا وابسته نیست. زیرا ارزش آن از طریق نیروهای بازار مشخص می‌شود و فاقد ارزش ذاتی بسیار زیادی است. فرضیه دایربرگ (۲۰۱۶) بیان می‌کند که بیت‌کوین چیزی بین طلا و ارز است.

مروری بر پیشینه پژوهش

با توجه به اهمیت نوسانات داده‌های مالی در مدیریت ریسک و بهینه‌سازی پرتفو، در سال‌های گذشته طیف گسترده‌ای از مطالعات در این زمینه انجام یافته است. با توجه به موجود بودن این مطالعات در پیشینه مقاله سایر مقالات داخلی، در این بخش صرفاً به بررسی مطالعات صورت گرفته با استفاده از مدل‌های ترکیبی شبکه عصبی و خانواده GARCH در پیش‌بینی نوسانات بازدهی دارایی‌های مالی پرداخته می‌شود.

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

در مطالعات خارجی، کریستجان پولر و میناتو^{۱۶} (۲۰۱۸) در مطالعه‌ای به اندازه گیری نوسانات قیمت بیت کوین با استفاده از مدل ترکیبی GARCH-ANN از ۱۳ دسامبر ۲۰۱۱ تا ۲۶ آگوست ۲۰۱۷ برای سه دوره ۱۰، ۲۲، ۴۴ روزه پیش بینی کردند. در این مقاله مدل ترکیبی در مقایسه با مدل های فردی و رقیب، دقت پیش بینی نوسان قیمت را به میزان قابل توجهی افزایش داد.

صدیق و همکاران^{۱۷} (۲۰۱۸) در مطالعه‌ای به جهت رسیدن به مدلی برای پیش بینی نوسان میزان سرمایه گذاری و رشد بودجه شرکت های مدیریت دارایی در پاکستان برای یک دوره پنج ماهه پرداخته و مدل ترکیبی GARCH-ANN را که دارای خطای پیش بینی کمتری نسبت به سایر مدل ها بود را پیشنهاد کردند.

کریستجان پولر و هرناندز^{۱۸} (۲۰۱۷) با استفاده از داده های 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 شاخص های سهام چین، هند، آمریکا به پیش بینی نوسان شاخص این سه فلز با مدل GARCH پرداخته و سپس این مدل را به عنوان ورودی شبکه عصبی به کار بردند. نتایج حاصله نشان داد که مدل ترکیبی قدرت پیش بینی نوسان خارج از نمونه این سه فلز را افزایش می دهد. در نهایت برای پیش بینی این نوسانات مدل GARCH-ANN پیشنهاد شد.

فاتیما^{۱۹} (۲۰۱۷) با استفاده از مدل های خانواده GARCH (EGARCH, α -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 پیش بینی نوسانات این دو شاخص طی مدت ۱۵ روز پرداختند. سپس میزان خطای مدل های ترکیبی را با استفاده از شاخص مجذور مربع خطاها^{۲۱} RMSE مقایسه نمودند و به این نتیجه دست یافتند که مدل ترکیبی AGARCH-ANN دارای خطای پیش بینی کمتری نسبت به مدل های رقیب است.

لحمیری^{۲۲} (۲۰۱۷) با استفاده از مدل های ترکیبی GARCH-ANN و EGARCH-ANN با سه توزیع نرمال، t-student، و GED^{۲۳} و با استفاده از داده های روزانه دلار کانادا و یورو از ۴ ژون ۲۰۱۰ تا ۶ دسامبر ۲۰۱۵ به پیش بینی نوسان داده ها برای مدت ۲۰ روز پرداخته و سپس با استفاده از دو شاخص قدر مطلق میانگین خطا^{۲۴} MAE و مربع میانگین خطا^{۲۵} MSE نتایج را مورد مقایسه قرار دادند و به این نتیجه دست یافتند که مدل ترکیبی EGARCH-ANN با توزیع GED توانایی بهتری در پیش بینی نوسان دلار کانادا و یورو دارد.

لو و همکاران^{۲۶} (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.

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 سعیدی و محمدی (۱۳۹۱) با استفاده از مدل‌های ترکیبی GARCH-ANN به پیش‌بینی نوسانات شاخص کل بورس اوراق بهادار 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 مقاله 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 دارند؛ بنابراین انجام دادن چنین پژوهش‌هایی باهدف تصحیح خطای پیش‌بینی در نوسان بازار سرمایه برای دریافت اطلاعات لازم موردنیاز 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.

مبانی ریاضی مدل‌های تحقیق و نحوه اندازه‌گیری متغیرها

مدل‌های ARMA^{۲۷} و ARIMA^{۲۸}

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

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

که یک فرآیند خود رگرسیون انباشته با میانگین متحرک از مرتبه p, d, q است و به ترتیب نشان دهنده تعداد جملات خود توضیحی، مرتبه تفاضل‌گیری و تعداد جملات میانگین متحرک است و x_t را انباشته از مرتبه d می‌نامند که به صورت $I(d)$ نمایش داده می‌شود. در صورتی که d برابر با صفر شود، فرآیند

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

ARIMA به ARMA تبدیل می‌شود. برای تخمین مدل‌های ARMA و ARIMA از روش باکس-جنکینز^{۲۹} استفاده می‌شود. در این روش تعداد جملات p و q با استفاده از توابع خود همبستگی^{۳۰} AC و خودهمبستگی جزئی^{۳۱} PAC محاسبه می‌شود و دقت آن‌ها با استفاده از معیارهای آکائیک^{۳۲} AIC، شوارتز-بیزین^{۳۳} SBC یا حنان-کوئین^{۳۴} HQIC محاسبه می‌شود و با هدف قرار دادن حداقل میزان این معیارها تعداد جملات p و q مشخص می‌گردد.

مدل‌های خانواده GARCH

برای ارائه یک تصویر مناسب از مدل‌های تلاطم میانگین شرطی و واریانس شرطی، بازدهی سری‌های زمانی به صورت r به شرط وجود اطلاعات Ω_{t-1} به صورت زیر نمایش داده می‌شود:

$$r_t = \Phi_0 + \sum_{i=1}^p \Phi_i r_{t-i} - \sum_{i=1}^q \theta_i a_{t-i} + a_t \quad (2)$$

$$E[r_t | \Omega_{t-1}] = \Phi_0 + \sum_{i=1}^p \Phi_i r_{t-i} - \sum_{i=1}^q \theta_i a_{t-i} + a_t \quad (3)$$

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

$$\sigma^2 = \text{var}(r_t | \Omega_{t-1}) = \text{var}(a_t | \Omega_{t-1}) \quad (4)$$

به معادله واریانس شرطی (ARCH) برای نخستین بار توسط انگل ارائه شد. اگرچه مدل‌های ARCH به خاطر وجود سادگی دارای برتری اند اما در برخی موارد برای توصیف تلاطم‌ها^{۳۵} نیاز به تعداد قابل توجهی پارامتر a_t است. به همین خاطر بولرسلو مدلی را تعریف می‌کند که دارای پارامتر کمتری بوده و از نظر کفایت مشخصه‌نمایی مدل در وضعیت بهتری نسبت به مدل ARCH قرار دارد که به آن، مدل GARCH گفته می‌شود و به صورت زیر نمایش داده می‌شود:

$$a_t = \sigma_t \varepsilon_t \quad (5)$$
$$r_t = \Phi_0 + \sum_{i=1}^p \Phi_i r_{t-i} - \sum_{i=1}^q \theta_i a_{t-i} + a_t$$

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

اگر معادله دارای ریشه واحد باشد به آن مدل GARCH انباشته یا IGARCH می‌گویند که مدل محدودشده‌ای از معادله (۶) 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^{۳۶} 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 σ^2 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^{۳۷} (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:

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

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

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

در معادله بالا

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

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

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

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

که واریانس شرطی در آن به صورت زیر تعریف می‌شود:

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

که d می‌تواند مقادیری بین صفر و یک داشته باشد و تمامی ریشه‌های $\phi(L)$ و $[1-\beta(L)]$ خارج از دایره واحدند.

حافظه بلندمدت و انباشتگی کسری

یکی از ویژگی‌های مشاهده شده در بسیاری از داده‌های سری زمانی مالی، وجود حافظه بلندمدت در میانگین و واریانس شرطی آن‌ها است. بدین صورت که اثر شوک‌های وارد شده بر سری‌های زمانی دیرپا بوده و مدت زمان زیادی طول می‌کشد که اثر این شوک‌ها در بازدهی دارایی و تلاطم آن‌ها از بین برود. یک روش برای مدل‌سازی چنین رفتاری در این سری‌ها استفاده از فرآیند انباشته کسری است که این مدل‌ها می‌تواند 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 می‌کند و در واقع دارای حافظه بلندمدت‌اند. این فرآیندها می‌تواند هم در مدل‌های میانگین شرطی به کار برده شوند که در این صورت این فرآیندها را ARFIMA و هم در فرآیند واریانس شرطی به کار برده شود که به صورت انباشتگی شرطی نوسانات FIGARCH و FIGARCH مورد استفاده قرار گیرند. با توجه به ویژگی‌های سری زمانی با وجود 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^{38} و GPH^{39} استفاده شده است.

شبکه عصبی بازگشتی

شبکه‌های عصبی بازگشتی یا RNN (راملههارت و همکاران، ۱۹۸۶) خانواده‌ای از شبکه‌های عصبی برای پردازش داده‌های ترتیبی هستند. شبکه عصبی تراجعی یک شبکه‌ی عصبی است که مختص پردازش دنباله‌ای

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و هفتم / تابستان ۱۴۰۰

از مقادیر $x^{(1)}, \dots, x^{(n)}$ است. از نظر تئوری RNN ها بایستی قادر به مدیریت و استفاده بهینه از محتوای موجود در یک دنباله باشند. در عمل اما اینگونه نیست و RNN های معمولی با کاستی مواجه هستند. به همین دلیل نیز استفاده از RNN ها تا مدتی متوقف گردید تا اینکه نتایج بسیار خوبی با استفاده از واحد حافظه بلندمدت و کوتاه مدت یا به اختصار LSTM مخفف (Long Short Term Memory) در شبکه عصبی بدست آمد. برخلاف RNN سنتی LSTM ها در مواجهه با دنباله‌های طولانی مشکلی نداشته و با مکانیزم طراحی شده در آنها به خوبی اجازه کار با دنباله‌های طولانی‌تر را می‌دهند. مدلی که در این پژوهش نیز به کار گرفته شده است LSTM می‌باشد.

برخلاف شبکه عصبی بازگشتی سنتی که صرفاً جمع متوازن سیگنال‌های ورودی را محاسبه کرده و سپس از یک تابع فعالساز عبور می‌دهد هر واحد LSTM از یک حافظه C_t در زمان t بهره می‌برد. خروجی h_t و یا فعالساز واحد LSTM بصورت $h_t = F_0 \cdot \tanh(C_t)$ است که در آن F_0 دروازه خروجی است که کنترل کننده میزان محتوایی است که از طریق حافظه ارائه می‌شود. دروازه خروجی از طریق عبارت $F_0 = \sigma(W_0 \cdot [h_{t-1}, X_t] + b_0)$ محاسبه می‌شود که در σ تابع فعالساز softmax است. W_0 نیز یک ماتریس اوریب است. سلول حافظه C_t نیز با فراموشی نسبی حافظه فعلی و اضافه کردن محتوای حافظه جدید بصورت \hat{C}_t بصورت $\hat{C}_t = F_f \cdot C_{t-1} + F_u \cdot \hat{C}_t$ به روزرسانی می‌شود که در آن محتوای حافظه جدید از طریق عبارت $\hat{C}_t = \tanh(W_C \cdot [h_{t-1}, X_t] + b_c)$ بدست می‌آید. آن میزان از حافظه فعلی که باید فراموش شود توسط دروازه فراموشی F_f کنترل می‌شود و آن میزانی از محتوای حافظه جدید که باید سلول حافظه اضافه شود توسط دروازه به‌روزرسانی (یا بعضاً به دروازه ورودی معرف است) انجام می‌گیرد. این عمل با محاسبات زیر صورت می‌گیرد:

$$F_f = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (16)$$

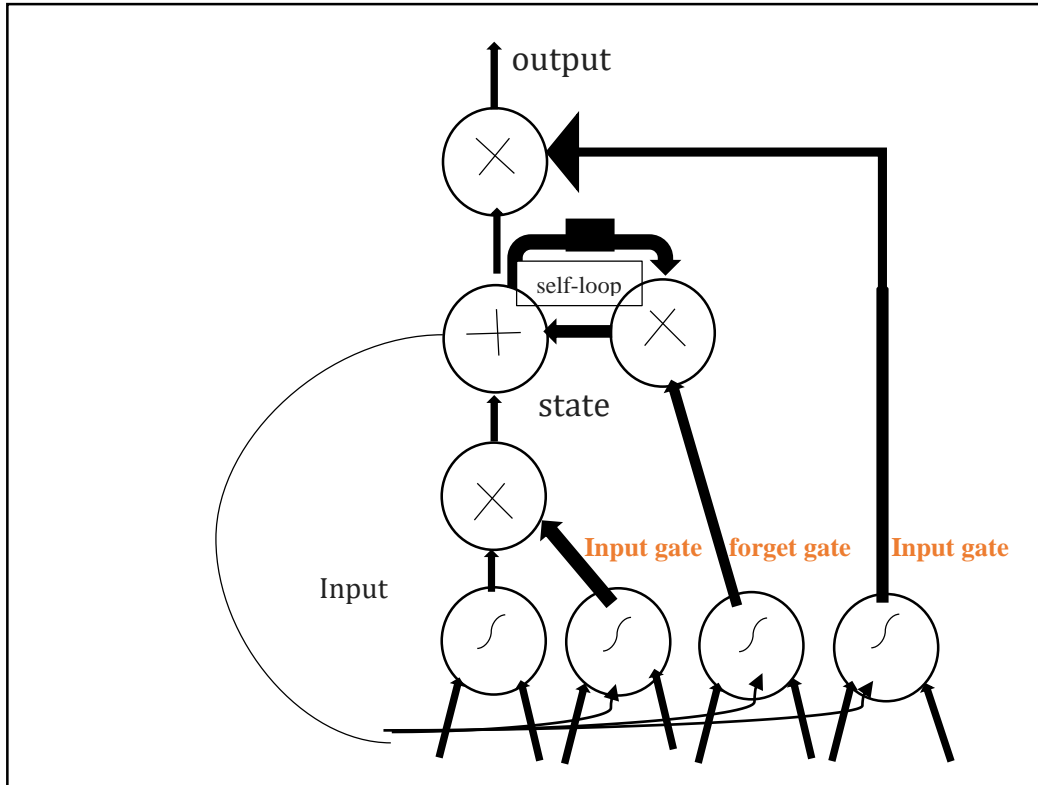
$$F_u = \sigma(W_u \cdot [h_{t-1}, X_t] + b_u) \quad (17)$$

حال برای بررسی شبکه LSTM ابتدا یک شبکه RNN استاندارد را بررسی می‌کنیم سپس یک شبکه LSTM را مورد بررسی قرار می‌دهیم.

در نسخه‌های بهبود یافته همانند LSTM می‌بینیم که ما با اعمال محدودیت در آزادی پارامترها (با قرار دادن دروازه‌های جدید) در فرایند بهینه سازی این قابلیت را به شبکه ارائه می‌کنیم. در نمودار (۱) ما شاهد یک شبکه عصبی بازگشتی LSTM هستیم.

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

نمودار ۱: شبکه LSTM



منبع: بان گودفلو

شبکه عصبی کانولوشنی

شبکه‌های عصبی کانولوشنی یا CNN (راملهارت و همکاران، ۱۹۸۶) خانواده‌ای از شبکه‌های عصبی برای پردازش داده‌های تصویر هستند. شبکه عصبی کانولوشنی یک شبکه‌ی عصبی است که مختص پردازش تصاویر است. از نظر تئوری CNN ها در حوزه‌ی داده‌های دنباله‌ای مورد استفاده قرار نمی‌گیرند و غالباً در حوزه تصویر می‌باشند. در عمل در این مقاله از این شبکه جهت پیش‌بینی داده‌های دنباله‌ای استفاده شده است. به همین دلیل تغییراتی را در این شبکه حاصل نموده‌ایم که بتوان در حوزه پیش‌بینی داده‌های سری زمانی مورد استفاده قرار داد.

و همچنین در این شبکه از سه لایه کانولوشنی استفاده شده است و در نهایت بخشی که شبکه کانولوشنی جهت تخمین یک سری زمانی مورد استفاده قرار گرفته است.

مدل ترکیبی

با توجه به تجربیات مطالعات پیشین در بخش «۲» به نظر می‌رسد ترکیب مدل‌های بیان‌شده در بخش «۳» به عنوان مدلی در پیش‌بینی سری زمانی عملکرد بهتری نسبت به پیش‌بینی صورت گرفته با استفاده از هریک از این مدل‌ها خواهد داشت. بنابراین روشی که برای پیش‌بینی نوسان شاخص بورس از ترکیب دو مدل مطرح‌شده در بخش‌های بالا پیشنهاد شد، به این ترتیب که در مرحله نخست با استفاده از مدل‌های ARIMA سری میانگین شرطی سری زمانی شاخص کل بورس تخمین زده می‌شود. سپس واریانس شرطی با استفاده از مدل‌های خانواده GARCH براساس سه توزیع نرمال، تی-استیودنت و GED تخمین زده می‌شوند و به‌عنوان ورودی شبکه عصبی بازگشتی و کانولوشنی به همراه دو متغیر کنترلی نرخ طلا و قیمت نفت استفاده می‌گردد. در طراحی شبکه CNN-LSTM باتابع فعال سازی GradientDescentOptimizer که یکی از جدیدترین مدل‌ها در چارچوب مطالعات مالی است با ترکیب وزنی η متغیر ورودی از مجموعه نرون‌هایی استفاده شده که وظیفه پردازش اطلاعات را بر عهده دارند و در نهایت با استفاده از سه معیار MSE، MAE و RMSE مدل‌ها با هم مقایسه می‌شوند و مدل بهینه انتخاب می‌شوند.

تجزیه و تحلیل مدل و ارزیابی نتایج

داده‌ها و آزمون‌های اولیه

داده‌های مورد استفاده در این پژوهش بیت‌کوین است که به‌صورت روزانه از سال ۱۳۹۲ تا ۱۳۹۸ به تعداد ۲۰۰۰ مشاهده جمع‌آوری شده است. همچنین در این پژوهش از دو متغیر کنترلی قیمت نفت اوپک و قیمت طلا استفاده شده است. در ابتدا سری زمانی بازدهی این سه متغیر به‌صورت زیر استخراج می‌شود:

$$r_t = \frac{P_t - P_{t-1}}{P_t} \times 100 \quad (31)$$

که در آن r_t بازدهی و P_t 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.

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

جدول ۱: آمار توصیفی داده‌ها

آماره / داده	بیت کوین	بازدهی بیت کوین	نفت	بازدهی نفت	طلا	بازدهی طلا
میانگین	۹۶۶۳,۶۸	۰,۰۱۱۶۳۶	۶۴,۳۵۰۹	۰,۰۵۸۲۰۳	۱۴۲۴,۳	۰,۰۷۴۳۲
میانه	۸۵۳۶,۶۸	۰,۰۳۵۱۶۳	۷۴,۵۳	۰,۰۱۴۲۱۱	۳۱۱۴۹	۰
بیشینه	۱۹۱۶۶,۹۷	۶,۴۰۱۶۸	۱۲۴,۶۳	۴۳,۸۱۵۸۰	۴۴۲۸۹	۱۷,۰۹۲۸۶
کمینه	۱۶۰,۳	-۶,۵۱۲۵۰۸	۲۲,۴۷	-۱۰۰	۹۶۴۹	-۹,۵۲۳۸۰
انحراف معیار	۲۷۹۸۳,۹۵	۰,۶۶۱۷۲۲	۲۶,۴۳۰۱۴	۳,۶۳۹۶۷۸	۱۱۴۴۵,۴۶	۱,۱۷۴۳۷۳
چولگی	-۰,۰۲۹۳۵	۰,۴۲۰۵۵	-۰,۰۶۳۱۰۰	-۱۸,۱۳۹۷۰	-۰,۳۰۰۱۲۳	۱,۴۳۸۴۲۰
کشیدگی	۱,۳۶۷۲۱۰	۸,۵۴۸۶۶۲	۱,۵۳۸۰۱۳	۵۲۹,۵۰۵۰	۱,۳۶۸۴۶۵	۳۷,۶۸۱۷۱
آماره جاک برا	۲۴۴,۲۵۴۵	۲۸۷,۴۴۸۵	۱۹۶,۹۳۹۸	۲۵۴,۶۱۷۲۰	۲۷۶,۵۳۱۲	۱۱۰,۷۶۴
احتمال	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰

منبع: محاسبات تحقیق

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^{۴۰} و میزان احتمال آن نشان‌دهنده عدم نرمال بودن در شاخص‌ها و بازدهی آن‌ها است.

برای ارزیابی ریشه واحد متغیرهای مورد بررسی، با استفاده از سه آزمون دیکی-فولر تعمیم‌یافته^{۴۱} و فیلیپس پرون^{۴۲} و KPSS^{۴۳} 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. براساس نتایج سه آزمون فوق، 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
۲,۰۵	R/S
۰,۱۷۰	GPH

منبع: محاسبات تحقیق

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^{۴۴}

پس از تخمین مدل میانگین شرطی، جهت بررسی وجود اثر ARCH با انجام آزمون ضریب لاگرانژ بر روی پسماندهای سری زمانی بازده بیت‌کوین 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	۸۱,۷۹۰۸	<i>F – statistic</i>
۰,۰۰۰	۳۳۴,۱۱۴	<i>Chi – squared</i>

منبع: محاسبات تحقیق

تخمین مدل‌های خانواده GARCH

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

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

جدول ۵: مدل میانگین واریانس های برآورد شده بازده بیت کوین

مدل	توزیع	میانگین شرطی	واریانس شرطی
GARCH	نرمال	$y_t = 0.017 + 0.401y_{t-1}$ (۱.۰۵) (۱۷.۸)	$\sigma_t^2 = 0.023 + 0.193\varepsilon_{t-1}^2 + 0.762\sigma_{t-1}^2 + 0.002v_{oil} + 0.003v_{dollar}$ (۲.۳۰) (۳.۲۵) (۱۰.۶) (۰.۰۰۳) (۰.۰۰۲)
	T	$y_t = 0.042 + 0.924y_{t-1} - 0.517u_{t-1} - 0.282u_{t-2}$ (۲.۰۶) (۴۰.۷۵) (-۱۵.۷۸) (-۱۰.۶۲)	$\sigma_t^2 = 0.004 + 0.193\varepsilon_{t-1}^2 + 0.833\sigma_{t-1}^2 + 0.002v_{oil} + 0.001v_{dollar}$ (۲.۵۸) (۶.۰۲) (۳۶.۱۰) (۰.۰۰۲) (۰.۰۰۴)
	GED	$y_t = 0.051 + 0.932y_{t-1} - 0.530u_{t-1} - 0.283u_{t-2}$ (۳.۱۸۳) (۵۳.۴۵) (-۳۳.۰۱) (-۱۱.۲۰)	$\sigma_t^2 = 0.007 + 0.186\varepsilon_{t-1}^2 + 0.831\sigma_{t-1}^2 + 0.001v_{oil} + 0.001v_{dollar}$ (۳.۰۱) (۵.۷۶) (۲۹.۶۲) (۰.۰۰۱) (۰.۰۰۲)
EGARCH	نرمال	$y_t = 0.050 + 0.931y_{t-1} - 0.591u_{t-1} - 0.356u_{t-2}$ (۰.۳۱) (۲۸.۸۷) (-۱۵.۳۰) (-۷.۰۹)	$\ln \sigma_t^2 = -0.053 + 0.328 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } + 0.0620 \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + 0.923 \ln \sigma_{t-1}^2 - 0.029v_{oil} + 0.008v_{dollar}$ (-۴.۰۵) (۴.۳۸) (۸۵.۸۴) (۱۰.۰۵) (-۴.۶۲) (۰.۵۷)
	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) (۳.۳۷) (۷.۲۸) (-۲.۱۳۵) (۰.۹۵)
FIGARCH	نرمال	$y_t = 0.038 + 0.325y_{t-1} - 0.089u_{t-1}$ (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)
	T	$y_t = 0.039 + 0.396y_{t-1}$ (۲.۶۹) (۱۵.۹۶)	$\sigma_t^2 = 0.526 + 0.577\sigma_{t-1}^2 + [1 - (1 - 0.576L)^{-1}(1 - 0.238L)(1 - L)^{0.558}] \varepsilon_t^2 + 0.003v_{oil} + 0.003v_{dollar}$ (۲.۱۹) (۸.۰۵۲) (۶.۳۶) (۶.۳۲) (-۰.۲۸) (۰.۰۰۳)
	GED	$y_t = 0.044 + 0.293y_{t-1} - 0.014u_{t-1}$ (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) (۰.۰۴)
FIGARCH	نرمال	$y_t = 0.053 + 0.323y_{t-1} + 0.072u_{t-1}$ (۵.۹۸) (۳۳.۴۳) (۱۲.۷۱)	$\ln(\sigma_t^2) = 0.721 + 0.575(L)^{-1}(1 - L)^{-0.402} [1 + 0.147(L)] (0.088 \frac{\varepsilon_{t-1}}{ \sigma_{t-1} } + 0.338 \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } - E \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} }) - 0.018v_{oil} + 0.075v_{dollar}$ (۶.۷۲) (۷۳.۵۴) (۱.۱۹) (۴۳.۸۲) (۱.۹۱) (۶.۴۳) (-۰.۷۵)

$\ln(\sigma_t^2) = 0.814 + 0.943(L)^{-1}(1-L)^{0.513}[1 + 0.261(L)](0.042 \frac{\varepsilon_{t-1}}{ \sigma_{t-1} } + 0.467[\frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } - E \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} }]) - 0.002v_{oil} + 0.032v_{dollar}$ <p>(۱.۳۸) (۱۶۸.۵) (۱.۸۲) (-۱۴.۴۳) (۱.۴۲)(۷.۶۲) (-۰.۲۴) (۰.</p>	$y_t = 0.079 + 0.945y_{t-1} - 0.520u_{t-1} - 0.315u_{t-2}$ <p>(۲.۴۵) (۴۳.۲۰) (-۱۴.۴۹) (-۱۰.۵۶)</p>	T
$\ln(\sigma_t^2) = 0.883 + 0.457(L)^{-1}(1-L)^{-0.679}[1 - 0.323(L)](0.088 \frac{\varepsilon_{t-1}}{ \sigma_{t-1} } + 0.421[\frac{ \varepsilon_{t-1} }{ \sigma_{t-1} } - E \frac{ \varepsilon_{t-1} }{ \sigma_{t-1} }]) - 0.001v_{oil} + 0.032v_{dollar}$ <p>(۳.۸۹) (۱۷۸.۱۵) (۱۷۳.۱۵) (۱۷۸.۱۴) (۱.۱۲) (۷.۴۲) (-۰.۲۳)</p>	$y_t = 0.067 + 0.928y_{t-1} - 0.539u_{t-1} - 0.292u_{t-2}$ <p>(۲.۳۲) (۴۱.۴۱) (-۱۶.۳۴) (-۱۲.۱۶)</p>	GED

منبع: محاسبات تحقیق

با نگاهی به مدل‌های برآورد شده از خانواده‌های GARCH با سه توزیع نرمال، t و GED مشاهده می‌شود که واریانس شرطی از ساختار خانواده GARCH پیروی کرده و تفسیرهای مدل‌های انجام‌شده به ترتیب در زیر انجام می‌شود:

- در مدل‌های GARCH بر اساس سه توزیع نرمال، t و GED تفاوت زیادی بین مدل‌های میانگین و واریانس شرطی مشاهده نمی‌شود و ضرایب در این مدل به جز دو متغیر کنترلی معنادار هستند. عدم معنی‌داری این دو متغیر در این مدل نشان‌دهنده عدم اثرپذیری بر روی ضرایب ARCH و GARCH است که نشان‌دهنده عدم تغییر در واریانس شرطی مدل است. معنی‌داری ضرایب ARCH و GARCH در این مدل به معنای پیروی بازدهی بیت‌کوین از این مدل‌ها است.

- در مدل EGARCH بر اساس سه توزیع نرمال، t و GED همانند قبل تفاوت چندانی میان میانگین و واریانس شرطی مشاهده نمی‌شود و در این مدل ضریب واریانس طلا در هر سه توزیع بی‌معنی است و با توجه به معنی‌داری ضریب $\frac{\varepsilon_{t-1}}{\sigma_{t-1}}$ نشان‌دهنده واکنش نامتقارن بازده بیت‌کوین به شوک‌های خارجی و دارای اثر اهرمی^{۴۵} است، تاثیر گذاری غیر یکسان شوک‌های مثبت و منفی بر بیت‌کوین نشان می‌دهد که این خود نشان‌دهنده تاثیرپذیری بیت‌کوین از اخبار و شوک‌های خارجی است. همچنین معنی‌داری واریانس قیمت نفت در این مدل نشان‌دهنده سرایت تأثیر نوسانات قیمت نفت بر نوسانات بازدهی بیت‌کوین 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 طلا 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

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

واریانس شرطی معنی داری نشان دهنده وابستگی به تلاطم و شوک های دوره قبل است. همچنین بی معنی بودن ضرایب نفت و طلا در این مدل ها نشان دهنده عدم تاثیر این دو متغیر در درازمدت بر روی این مدل ها است.

- در مدل FIEGARCH نیز به همین ترتیب نشان دهنده وجود تلاطم و اثر اهرمی است در واقع تاثیر گذاری این اثرات بر بلند مدت بر بازدهی بیت کوین به معنای تاثیر و ماندگاری اخبار و شوک های خارجی در بلند مدت بر بیت کوین است، ولی بی معنی بودن ضرایب نفت و طلا در این مدل ها نیز نشان دهنده عدم تاثیر نوسان این دو مورد بر بیت کوین در بلندمدت است.

مدل ترکیبی

با توجه به مباحث مطرح شده، پس از تعیین وقفه های مناسب شبکه ای که دارای کمترین خطا بود، لایه ورودی با توجه به داده های ورودی شبکه عصبی (خروجی خانواده GARCH، قیمت نفت و قیمت طلا) در نظر گرفته شد. پس از تعیین ورودی های این شبکه، تعداد دوره های آموزش و آزمایش این شبکه به نسبت ۷۰ به ۳۰ درصد تعیین و با نرخ یادگیری ۱ درصد استفاده شد. در نهایت خروجی های این مدل به همراه خروجی های مقادیر واقعی سنجش و میزان خطای آن ها بر حسب مقدار RMSE و MAE و MSE محاسبه و نتایج زیر حاصل گردید. شایان ذکر است پیش بینی نهایی بیت کوین با تجمیع پیش بینی مدل میانگین شرطی (ARMA) و پیش بینی هر یک مدل های اشاره شده در فوق محاسبه شد.

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	۰.۱۴۲۴۲	۰.۱۲۸۷۲	۰.۱۲۹۳۱	۰.۱۱۹۱۸	۰.۱۴۲۰۲	۰.۱۷۶۸۸	۰.۲۱۲۳۲	
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	
RNN-CNN -GARCH-N	۰.۱۵۶۸۷	۰.۱۵۹۹۸	۰.۱۶۱۱۳	۰.۱۶۴۷۶	۰.۱۶۷۲۵	۰.۱۶۹۵۶	۰.۱۷۲۳۴	۰.۱۷۵۱۲	۰.۱۷۸۹۸	۰.۱۸۱۶۶	
RNN-CNN -GARCH-t	۰.۰۴۲۱۳	۰.۰۴۴۵۵	۰.۰۷۶۳۲	۰.۰۷۴۹۸	۰.۰۸۱۲۱	۰.۰۷۳۵۶	۰.۰۵۵۲۲	۰.۰۷۸۳۴	۰.۰۹۰۱۸	۰.۰۷۲۲۷	
RNN-CNN -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	۰.۱۵۶۳	۰.۱۴۵۹۵	۰.۱۶۳۴۸	۰.۱۹۸۸	۰.۲۳۴۱۲	
RNN-CNN -EGARCH-N	۰.۱۵۸۰۸	۰.۱۶۲۵۱	۰.۱۶۷۰۴	۰.۱۷۱۶۶	۰.۱۷۶۳۶	۰.۱۸۱۳	۰.۱۸۶۰۱	۰.۱۹۰۹۳	۰.۱۹۵۹	۰.۲۰۱۰۴	
RNN-CNN -EGARCH-t	۰.۰۱۴۲۹	۰.۰۱۳۷۰	۰.۰۱۳۱۱	۰.۰۱۲۵۱	۰.۰۱۱۹۲	۰.۰۱۱۸۴	۰.۰۷۰۷۶	۰.۰۸۰۲۱	۰.۰۷۹۶	۰.۰۸۹۲۰	

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و هفتم / تابستان ۱۴۰۰

۰.۰۸۶۸۰	۰.۰۸۶۳۶	۰.۰۸۵۹۳	۰.۰۸۵۵۱	۰.۰۸۵۰۹	۰.۰۸۴۶۹	۰.۰۸۴۲۹	۰.۰۸۳۹۰	۰.۰۸۳۵۲	۰.۰۸۳۱۴	RNN-CNN -EGARCH-GED
۰.۳۶۱۵۸	۰.۳۰۱۱۷	۰.۲۴۲۸۴	۰.۲۰۴۲۲	۰.۲۲۰۵۸	۰.۲۱۹۶۱	۰.۲۴۳۲۵	۰.۲۷۷۷۷	۰.۲۵۳۸۳	۰.۰۰۰۲۷	FIGARCH-N
۰.۳۵۹۹۳	۰.۳۰۰۰۲	۰.۲۴۲۴۶	۰.۲۰۴۹۰	۰.۲۲۱۳۲	۰.۲۱۹۶۶	۰.۲۴۳۵۸	۰.۲۷۷۸۰	۰.۲۵۶۲۶	۰.۰۰۰۱۳	FIGARCH-t
۰.۳۵۹۷۷	۰.۲۹۹۵۲	۰.۲۴۱۴۱	۰.۲۰۳۱۴	۰.۲۱۹۴۲	۰.۲۱۷۶۳	۰.۲۴۱۲۰	۰.۲۷۵۱۸	۰.۲۴۹۵۳	۰.۰۳۸۰۰	FIGARCH-GED
۰.۰۳۷۲۳	۰.۰۶۷۸۸	۰.۰۷۸۵۲	۰.۰۷۹۱۶	۰.۰۷۹۷۹	۰.۰۸۰۰۴	۰.۰۸۱۰۵	۰.۰۰۱۶۷	۰.۰۰۲۲۹	۰.۰۰۰۹۰	RNN-CNN -FIGARCH-N
۰.۳۴۲۳۱	۰.۳۳۷۳۹	۰.۳۳۲۵۴	۰.۳۲۷۷۵	۰.۳۲۳۱۳	۰.۳۱۸۳۹	۰.۳۱۳۸۲	۰.۳۰۹۳۲	۰.۳۰۴۹۰	۰.۳۰۰۵۶	RNN-CNN -FIGARCH-t
۰.۳۳۵۲۴	۰.۳۳۲۸۲	۰.۳۳۰۳۹	۰.۳۲۷۹۵	۰.۳۲۵۴۹	۰.۳۲۳۰۳	۰.۳۲۰۵۶	۰.۳۱۸۰۱	۰.۳۱۴۶۰	۰.۳۱۳۰۱	RNN-CNN -FIGARCH-GED
۰.۳۶۰۲۸	۰.۳۰۰۱۸	۰.۲۴۲۳۱	۰.۲۰۴۳۴	۰.۲۲۰۷۱	۰.۲۱۹۱۹	۰.۲۴۲۸۷	۰.۲۷۷۲۲	۰.۲۵۳۰۶	۰.۰۹۱۳۰	FIEGARCH-N
۰.۳۵۱۶۴	۰.۲۹۶۲۵	۰.۲۴۵۵۹	۰.۲۱۶۹۵	۰.۲۳۴۰۱	۰.۲۲۸۷۶	۰.۲۵۵۲۳	۰.۲۸۸۲۷	۰.۲۸۹۳۵	۰.۱۱۱۹۵	FIEGARCH-t
۰.۳۵۳۲۲	۰.۲۹۶۸۷	۰.۲۴۴۵۳	۰.۲۱۳۹۰	۰.۲۳۰۸۵	۰.۲۲۶۷۲	۰.۲۵۲۶۰	۰.۲۸۶۳۱	۰.۲۸۱۰۶	۰.۱۰۸۸۷	FIEGARCH-GED
۰.۱۷۳۸۰	۰.۱۷۲۱۳	۰.۱۷۰۴۷	۰.۱۶۸۶۵	۰.۱۶۷۱۲	۰.۱۶۵۵۱	۰.۱۶۳۹۷	۰.۱۶۲۳۷	۰.۱۶۰۷۸	۰.۱۵۹۲۱	RNN-CNN -FIEGARCH-N
۰.۰۵۱۲۶	۰.۰۴۰۱۱	۰.۰۴۲۰۲	۰.۰۴۱۰۰	۰.۰۴۱۰۶	۰.۰۴۱۱۸	۰.۰۴۰۲۷	۰.۰۳۲۶۲	۰.۰۳۲۹۴	۰.۰۳۲۳۳	RNN-CNN -FIEGARCH-t
۰.۰۶۰۳۲	۰.۰۶۰۹۶	۰.۰۶۱۵۰	۰.۰۶۲۲۲	۰.۰۶۲۸۵	۰.۰۶۳۳۸	۰.۰۶۴۰۰	۰.۰۶۴۶۲	۰.۰۶۵۲۲	۰.۰۶۵۲۴	RNN-CNN -FIEGARCH-GED

جدول ۷: خطای پیش‌بینی 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	۰.۰۱۴۳	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
RNN-CNN -GARCH-N		۰.۰۲۴۶	۰.۰۲۵۳۹	۰.۰۲۶۲۱	۰.۰۲۷۰۷	۰.۰۲۷۹۶	۰.۰۲۸۸۸	۰.۰۲۹۸۳	۰.۰۳۰۸۲	۰.۰۳۱۸۵	۰.۰۳۲۹۱
RNN-CNN -GARCH-t		۰.۰۰۱۸۳	۰.۰۰۲۰۱	۰.۰۰۲۲	۰.۰۰۲۴	۰.۰۰۲۶۲	۰.۰۰۲۸۶	۰.۰۰۳۱۱	۰.۰۰۳۳۷	۰.۰۰۳۶۵	۰.۰۰۳۹۵
RNN-CNN -GARCH-GED		۰.۰۳۳۸۱	۰.۰۳۵۷۴	۰.۰۳۷۷۹	۰.۰۳۹۹۷	۰.۰۴۲۲۹	۰.۰۴۴۷۵	۰.۰۴۷۳۶	۰.۰۵۰۱۳	۰.۰۵۳۰۶	۰.۰۵۶۱۸
EGARCH-N		۰.۰۰۰۰۹	۰.۰۲۵۴۱	۰.۰۲۸۱۲	۰.۰۲۱۷۸	۰.۰۱۷۶۲	۰.۰۱۸۱۸	۰.۰۱۵۵۹	۰.۰۲۱۱۷	۰.۰۳۱۹۳	۰.۰۴۵۶۹
EGARCH-t		۰.۰۰۲۳۳	۰.۰۸۷۴۴	۰.۰۸۲۰۸	۰.۰۶۵۳۸	۰.۰۵۲۳۶	۰.۰۵۶۰۹	۰.۰۴۸۳۵	۰.۰۶۰۲۵	۰.۰۸۶۳۳	۰.۱۲۱۳۵
EGARCH-GED		۰.۰۰۷۹۴	۰.۰۵۰۱۴	۰.۰۴۰۷۲	۰.۰۳۰۸	۰.۰۲۴۶۶	۰.۰۲۴۴۵	۰.۰۲۱۳	۰.۰۲۶۷۳	۰.۰۳۹۵۶	۰.۰۵۴۸۱
RNN-CNN -EGARCH-N		۰.۰۲۴۹۹	۰.۰۲۶۴۱	۰.۰۲۷۹	۰.۰۲۹۴۷	۰.۰۳۱۱	۰.۰۳۲۸۱	۰.۰۳۴۶	۰.۰۳۶۴۶	۰.۰۳۸۴	۰.۰۴۰۴۲
RNN-CNN -EGARCH-t		۰.۰۱۰۲	۰.۰۳۰۱۹	۰.۰۴۰۱۷	۰.۰۴۰۱۶	۰.۰۶۰۱۴	۰.۰۸۰۱۳	۰.۰۸۰۱۲	۰.۰۹۰۱	۰.۰۷۰۹	۰.۰۶۵۰۸
RNN-CNN -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
RNN-CNN -FIGARCH-N		۰.۰۱۱۰۱	۰.۰۱۰۴۶	۰.۰۱۰۳۴	۰.۰۱۰۲۱	۰.۰۱۰۴۳	۰.۰۱۰۳۷۰	۰.۰۴۳۰۱	۰.۰۷۸۷۱	۰.۰۴۳۰۵	۰.۰۳۸۹۴۵

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

۰.۰۸۰۴۵	۰.۰۵۰۵۸	۰.۰۴۰۷۱	۰.۰۰۳۰۱	۰.۰۲۲۹	۰.۰۱۰۰۸	۰.۰۱۰۲۱	۰.۰۱۰۳۴	۰.۰۱۰۴۶	۰.۰۰۱۰۱	RNN-CNN-FIGARCH-t
۰.۱۱۲۳۸	۰.۱۱۰۷۷	۰.۱۰۹۱۶	۰.۱۰۷۵۵	۰.۱۰۵۹۴	۰.۱۰۴۳۵	۰.۱۰۲۷۶	۰.۱۰۱۱۷	۰.۰۹۹۶	۰.۰۹۸۰۴	RNN-CNN-FIGARCH-GED
۰.۱۲۹۸	۰.۰۹۰۱۱	۰.۰۵۸۷۱	۰.۰۴۱۷۵	۰.۰۴۸۷۱	۰.۰۴۸۰۵	۰.۰۵۹۰۳	۰.۰۷۶۸۵	۰.۰۶۴۰۴	۰.۰۰۸۳۴	FIGARCH-N
۰.۱۲۳۶۵	۰.۰۸۷۷۶	۰.۰۶۰۳۱	۰.۰۴۷۰۷	۰.۰۵۴۷۶	۰.۰۵۲۳۳	۰.۰۶۵۱۴	۰.۰۸۳۱	۰.۰۸۳۷۳	۰.۰۱۲۵۳	FIGARCH-t
۰.۱۲۴۷۶	۰.۰۸۸۱۳	۰.۰۵۹۸۴	۰.۰۴۵۷۵	۰.۰۵۳۲۹	۰.۰۵۱۴	۰.۰۶۳۸۱	۰.۰۸۱۹۷	۰.۰۷۹	۰.۰۱۱۸۵	FIGARCH-GED
۰.۰۳۰۲۱	۰.۰۲۹۶۳	۰.۰۲۹۰۷	۰.۰۲۸۵۱	۰.۰۲۷۹۶	۰.۰۲۷۴۲	۰.۰۲۶۸۹	۰.۰۲۶۳۷	۰.۰۲۵۸۵	۰.۰۲۵۳۵	RNN-CNN-FIGARCH-N
۰.۰۰۰۱۱۴	۰.۰۰۱۰۹	۰.۰۰۱۱۳	۰.۰۰۱۱۲	۰.۰۰۱۱۵	۰.۰۰۱۱۵	۰.۰۰۱۳۵	۰.۰۰۱۲۰	۰.۰۰۱۲۴	۰.۰۰۱۲۵	RNN-CNN-FIGARCH-t
۰.۰۰۰۱۲	۰.۰۰۱۲۶	۰.۰۰۳۹۳	۰.۰۰۳۸۶	۰.۰۰۳۹۴	۰.۰۰۴۰۲	۰.۰۰۴۱۰	۰.۰۰۴۱۸	۰.۰۰۴۲۶	۰.۰۰۴۲۵	RNN-CNN-FIGARCH-GED

منبع: محاسبات تحقیق

جدول ۸: خطای پیش‌بینی بر اساس معیار MAE

مدل	گام	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
GARCH-N		۰.۰۱۱۱۷	۰.۰۵۱۵	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
RNN-CNN-GARCH-N		۰.۱۵۶۸۴	۰.۱۵۹۳۰	۰.۱۶۱۸۶	۰.۱۶۴۴۳	۰.۱۶۷۰۵	۰.۱۶۹۷	۰.۱۷۲۴	۰.۱۷۵۱۳	۰.۱۷۷۹۱	۰.۱۸۰۷۲
RNN-CNN-GARCH-t		۰.۰۴۲۷۱	۰.۰۴۴۷۱	۰.۰۴۶۷۶	۰.۰۴۸۸۱	۰.۰۵۰۸۹	۰.۰۵۳	۰.۰۵۵۱۲	۰.۰۵۷۲۱	۰.۰۵۹۴۴	۰.۰۶۱۶۳
RNN-CNN-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		۰.۰۵۷۷۱	۰.۲۳۵۹۰	۰.۲۴۶۳۰	۰.۲۱۵۶۵	۰.۱۷۵۹۵	۰.۱۹۲۱۹	۰.۱۷۰۹۴	۰.۱۹۶۹۳	۰.۲۳۵۴	۰.۲۷۷۶۰
EGARCH-GED		۰.۰۸۹۰۸	۰.۱۹۶۴۸	۰.۱۷۰۳	۰.۱۴۳۲۵	۰.۱۱۶۶۶	۰.۱۲۲۷۳	۰.۱۱۲۱۷	۰.۱۲۹۹۴	۰.۱۵۷۴۱	۰.۱۸۵۴۹
RNN-CNN-EGARCH-N		۰.۱۵۸۰۸	۰.۱۶۲۴۵	۰.۰۶۶۸۰	۰.۱۷۱۳۷	۰.۱۷۵۹	۰.۱۸۰۴۸	۰.۱۸۵۱۱	۰.۱۸۹۷۰	۰.۱۹۴۴۹	۰.۱۹۹۲۵
RNN-CNN-EGARCH-t		۰.۰۱۴۲۹	۰.۰۱۳۶۹	۰.۰۱۳۰۷	۰.۰۱۲۴۴	۰.۰۱۱۷۸	۰.۰۱۱۱۱	۰.۰۱۰۴۳	۰.۰۰۹۷۲	۰.۰۰۸۹۹	۰.۰۰۸۲۵
RNN-CNN-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
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	۰.۲۳۱۲۵	۰.۲۷۷۸۱
RNN-CNN-FIGARCH-N		۰.۱۰۲۹	۰.۱۰۲۲۸	۰.۱۰۱۶۷	۰.۱۰۱۰۴	۰.۱۰۰۴۱	۰.۰۹۹۷۷	۰.۰۹۹۱۳	۰.۰۹۸۴۱	۰.۰۹۷۷۱	۰.۰۹۷۱۶
RNN-CNN-FIGARCH-t		۰.۳۰۰۵۶	۰.۳۰۴۸۱	۰.۳۰۹۲۴	۰.۳۱۳۶۶	۰.۳۱۸۱۳	۰.۳۲۲۶۰	۰.۳۲۷۱۱	۰.۳۳۱۸۱	۰.۳۳۶۵	۰.۳۴۱۲۰
RNN-CNN-FIGARCH-GED		۰.۳۱۳۱۱	۰.۳۱۵۵	۰.۳۱۸۰۵	۰.۳۲۰۵۱	۰.۳۲۲۹	۰.۳۲۵۳	۰.۳۲۷۸	۰.۳۳۰۲	۰.۳۳۲۵	۰.۳۳۴۹
FIGARCH-N		۰.۰۰۹۱۳	۰.۲۱۸۶۷	۰.۲۵۴۴۱	۰.۲۰۸۰۳	۰.۱۷۹۲۲	۰.۱۸۷۳۰	۰.۱۶۰۶۵	۰.۱۹۳۲۲	۰.۲۳۶۶۱	۰.۲۸۲۷

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و هفتم / تابستان ۱۴۰۰

۰,۲۸۳۳	۰,۲۴۰۵۰	۰,۲۰۱۳۵	۰,۱۷۴۲۳	۰,۱۹۸۲۷	۰,۱۸۶۱۹	۰,۲۳۴۴۰	۰,۲۶۳۸۱	۰,۲۵۲۷۱	۰,۱۱۱۹۵	FIGARCH-t
۰,۲۸۳۲	۰,۲۳۹۷	۰,۱۹۹۶۷	۰,۱۷۱۳۲	۰,۱۹۶۱۲	۰,۱۸۵۲۵	۰,۲۲۱۰۵	۰,۲۶۲۵	۰,۲۴۵۵	۰,۱۰۸۸۷	FIGARCH-GED
۰,۱۷۳۵	۰,۱۷۱۹۴	۰,۱۷۰۳۴	۰,۱۶۸۷	۰,۱۶۷۱۲	۰,۱۶۵۴	۰,۱۶۳۹۳	۰,۱۶۲۳۶	۰,۱۶۰۷۸	۰,۱۵۹۲۲	RNN-CNN -FIGARCH-N
۰,۰۰۱۱۷	۰,۰۰۹۲۲	۰,۰۰۷۳۱	۰,۰۰۵۴۷	۰,۰۰۳۶۷	۰,۰۰۴۱۹۱	۰,۰۰۴۰۱	۰,۰۰۸۵۳	۰,۰۰۶۹۱	۰,۰۰۵۳۳	RNN-CNN-FIGARCH-t
۰,۰۶۰۲۲	۰,۰۶۰۸۸	۰,۰۶۱۵۳	۰,۰۶۲۱۸	۰,۰۶۲۸۲	۰,۰۶۳۴۶	۰,۰۶۴۰۹	۰,۰۶۴۷۱	۰,۰۰۵۳۳	۰,۰۰۹۴	RNN-CNN-FIGARCH-GED

منبع: محاسبات تحقیق

پس از تخمین مدل‌های مورد نظر و پیش‌بینی ۱۰ روز آتی (گام) بازدهی بیت‌کوین، برای مقایسه قدرت پیش‌بینی مدل‌های مورد نظر از معیارهای 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 می‌شود، میزان خطای این مدل‌ها به صورت تفکیک شده آورده شده است. برای هر یک از سه معیار مذکور، میزان خطا در گام‌های پیش‌بینی شده نسبت به بقیه گام‌ها برای بیشتر مدل‌ها کمتر است. در جدول (۶) که نشان دهنده میزان خطا بر اساس معیار $RMSE$ است در گام‌های ابتدایی مدل‌های $FIGARCH-N$ ، $FIGARCH-t$ و مدل‌های ترکیبی $RNN-CNN-EGARCH-t$ ، $RNN-CNN-FIGARCH-t$ ، $FIGARCH-N$ و $RNN-CNN-FIGARCH-t$ دارای کمترین میزان خطای پیش‌بینی است با افزایش میزان گام‌ها میزان دقت پیش‌بینی این مدل‌ها کاسته می‌شود. دقت مدل $RNN-CNN-FIGARCH-t$ نسبت به بقیه مدل‌ها به میزان کمتری کاهش می‌یابد. در جدول (۷) براساس شاخص MSE مدل‌های $EGARCH-N$ ، $FIGARCH-t$ ، $FIGARCH-GED$ و مدل $RNN-CNN-FIGARCH-t$ در گام‌های ابتدایی و مدل ترکیبی $RNN-CNN-FIGARCH-t$ به طور مجموع دارای خطای پیش‌بینی کمتری است بنابراین این مدل بر اساس این شاخص به عنوان مدل برگزیده انتخاب می‌گردد. در جدول (۸) نیز مدل‌های $RNN-CNN-EGARCH-t$ و $RNN-CNN-FIGARCH-t$ این ویژگی را دارند. در مجموع نتایج نشان دهنده این است که مدل‌های ترکیبی دارای خطای کمتری نسبت به بقیه مدل‌ها است و دقت پیش‌بینی با افزایش تعداد گام‌ها کاهش یافته است. همچنین با توجه به ویژگی عدم نرمال بودن بازدهی این شاخص که در جداول فوق نمایش داده شد، می‌توان بیان نمود که مدل‌هایی که دارای توزیع t و GED بودند به صورت دقیق‌تری قادر به پیش‌بینی نوسانات بیت‌کوین هستند.

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

پس از انتخاب مدل نهایی، در ادبیات پیش بینی از دو معیار دیبولد ماریانو^{۴۶} (DM) و دیبولدماریانو نامتقارن^{۴۷} (ADM) برای مقایسه نتایج معیارهای خطای (MSE, RMSE, MAE) مدل منتخب و سایر مدل های استفاده می شود. معادله (۳۲) ساختار آزمون DM را نشان می دهد.

$$DM = \frac{\bar{a}}{\sqrt{\frac{2\pi\hat{f}_a(0)}{T}}} \rightarrow N(0,1) \quad (32)$$

در این معادله \bar{a} میانگین تابع زیان و $2\pi\hat{f}_a(0)$ تخمین پیوسته واریانس متقارن و T دوره زمانی است. معادله (۳۳) نیز ساختار آزمون ADM را نشان می دهد.

$$L_a(e_{i,t}) = \begin{cases} a|e_{i,t}|^p & \text{if } e_{i,t} \geq 0 \\ |e_{i,t}|^p & \text{if } e_{i,t} < 0 \end{cases} \quad (33)$$

برتری ADM نسبت به DM در لحاظ پارامتر عدم تقارن در محاسبه تابع زیان می باشد. فرض صفر دو آزمون ADM و DM مبنی بر عدم وجود تفاوت معنادار در میان ارزش های معیارهای خطای می باشد.

پس از بررسی نتایج مدل منتخب با سایر مدل های رقیب مشاهده گردید که ارقام محاسبه شده بالاتر از قدر مطلق ۱/۹۸ واحد بود. بنابراین فرضیه صفر رد می گردد و برتری مدل منتخب تایید می شود.

انتخاب مدل بهینه

با توجه به مطالب بیان شده در بخش های قبلی مدل RNN-CNN-FIEGARCH-t به عنوان مدل بهینه که توانایی بالایی در پیش بینی نوسان این شاخص دارد برگزیده شد. انتخاب این مدل بر اساس توانایی آن در دقت پیش بینی در هر سه معیار دقت خطا است. بنابراین در این قسمت مدل ریاضی این مدل و ضرائب آن توضیح داده می شود. ساختار ریاضی این مدل و ضرائب آن در قسمت زیر آورده شده است:

$$\ln(\sigma_t^2) = 0.814 + 0.943(L)^{-1}(1-L)^{0.513}[1 + 0.261(L)](0.042\frac{\varepsilon_{t-1}}{|\sigma_{t-1}|} + 0.467[\frac{|\varepsilon_{t-1}|}{|\sigma_{t-1}|} - E\frac{|\varepsilon_{t-1}|}{|\sigma_{t-1}|}]) - 0.002v_{oil} + 0.032v_{aollar} \quad (31)$$

(۱.۳۸) (۱۶۸.۵) (۱.۸۲) (-۱۴.۴۳) (۱.۴۲) (۷.۶۳) (-۰.۲۴) (۰.۷۳)

در این مدل معنادار بودن اثرات میانگین نشان دهنده این است که بازدهی هر دوره به صورت ضربی از بازدهی و شوک های 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 بیت کوین است. همچنین وجود اثرات GARCH در این مدل که ضریب آن به صورت ۰,۹۳۴ نمایش داده می شود به دلیل وجود معنی داری این در ساختار تایید می شود. در این مدل اثرات شوک های نامتقارن

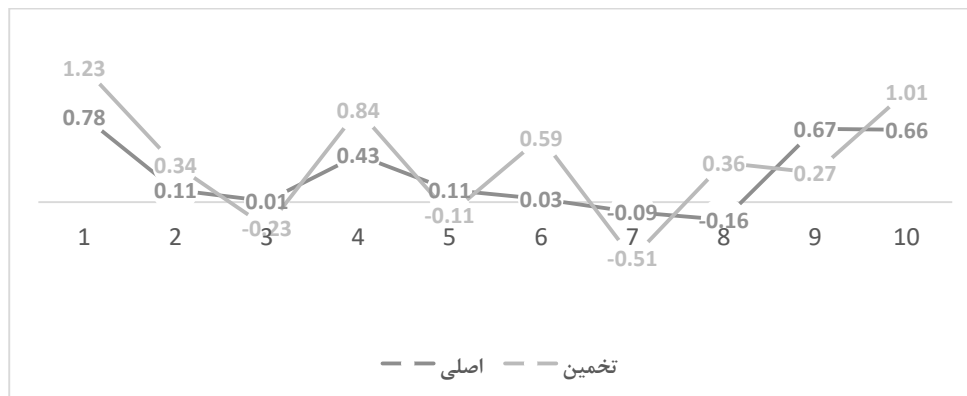
فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و هفتم / تابستان ۱۴۰۰

که به صورت EGARCH نمایش داده می‌شود نیز با ضرائب 0.052 و 0.588 تایید می‌گردد. وجود حافظه بلندمدت در این مدل نیز که مقدار آن با 0.504 نمایش داده شده است تایید می‌شود. میرا شدن این حافظه در بلندمدت 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 طلا که به صورت واریانس شرطی به این مدل اضافه شده نشان دهنده آن است که این متغیرها در بلند مدت تاثیری بر روی بیت‌کوین مورد نظر ندارد و امکان آنکه قیمت نفت و طلا بتواند تاثیر خود را در زمان بر روی بازدهی بیت‌کوین حفظ کند وجود ندارد. اما این به معنای عدم تاثیرگذاری نفت بر بیت‌کوین نیست همانگونه که در سایر مدل‌ها نشان داده شد نفت تاثیرگذاری خود را بر روی بیت‌کوین در کوتاه مدت دارد، میتوان این نتیجه را گرفت هرچه شوک‌های قیمتی نفت بر نوسانات بیت‌کوین تاثیری مستقیم حداقل در کوتاه مدت دارد.

پیش‌بینی بازده بیت‌کوین

در واقع پس مدل‌سازی بر روی 70% درصد از داده‌ها به بررسی مدل بر روی 30% درصد باقیمانده داده‌ها پرداخته شده است و سپس به سراغ داده‌های اصلی جهت پیش‌بینی رفته‌ایم.

پس از انجام پیش‌بینی و انتخاب مدل بهینه RNN-CNN-FIEGARCH-t، برای درک پیش‌بینی به گونه شهودی‌تر و اینکه مقادیر پیش‌بینی شده به مقادیر واقعی چه میزان نزدیک‌است، نمودار آن برای مقادیر واقعی و پیش‌بینی شده به صورت زیر آورده شده است. همانگونه که مشاهده می‌شود تفاوت مقادیر پیش‌بینی شده در این نمودار به مقادیر واقعی مشخص است.



نمودار ۱: مقایسه پیش‌بینی مدل ترکیبی RNN-CNN-FIEGARCH-t با مقادیر واقعی

منبع: محاسبات تحقیق

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

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 مقاله های مالی است. در این مقاله، مدل های خانواده گی ترکیبی RNN-CNN-GARCH(X)-ARMA برای پیش بینی نوسانات بیت کوین مورد بررسی قرار گرفته است. سپس مدل ترکیبی از خانواده GARCH و شبکه یادگیری عمیق جهت پیش بینی نوسانات بیت کوین 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 مقاله این مطلب را تصدیق نمود که مدل های ترکیبی RNN-CNN-EGARCH با توزیع t و GED و مدل های ترکیبی RNN-CNN-FIGARCH با توزیع نرمال و مدل RNN-CNN-FIEGARCH با توزیع نرمال، t و GED دارای کمترین میزان خطا بودند. علاوه بر این مدل های RNN-CNN-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 بیت کوین دارند. همچنین وجود حافظه بلند مدت در این مدل ها باعث شده که مدل های دارای این ویژگی، قادر به توضیح حرکات نوسان بیت کوین باشند. نتایج حاصل شده نشان دهنده این مطلب است که مدل های ترکیبی خانواده GARCH دارای حافظه بلندمدت با شبکه عصبی به طور خاص RNN-CNN-t-FIEGARCH در پیش بینی نوسان بازده بیت کوین کارآمدتر و دارای خطای پیش بینی کمتری هستند. در این پژوهش نوسانات بازار نفت به عنوان عوامل مهم و تاثیرگذار در بیت کوین معرفی گردید، بنابراین سرمایه گذاران بازارهای مالی می توانند با در نظر گرفتن این نوسانات به بهینه سازی سبد پورتفوی خود (به نحوی که کمترین آسیب را از نوسانات بازارهای نفت دریافت نمایند) بپردازند. به طور خلاصه، مشخص شد که مدل های RNN-CNN می توانند عملکرد پیش بینی مدل خانواده GARCH را در بیت کوین نمایش دهند و نشان داده شد که نتایج قابل اتکایی ارائه می دهند. در نهایت با توجه به اینکه پیش بینی تغییر پذیری یا نوسان در مدیریت ریسک، ارزش گذاری سبد سرمایه، قیمت گذاری مشتقات و ... کاربردهای فراوانی دارد؛ و از دیدگاه معامله گران بازار مشتقات، درک نوسان پذیری، پیش بینی دقیق آن و حفاظت از سبد دارایی های در مقابل هزینه هایی که این متغیر به ارزش کل تحمیل می کند، از اهمیت دوچندانی برخوردار است، استفاده از چنین ساختاری که تقریباً تمامی عوامل اثرگذار (اخبار سیاسی، شوک های داخلی و خارجی و ...) در این شاخص ها را در نظر می گیرد، می تواند مفید و کاربردی باشد.

منابع

- (۱) جباری حسین، نقدی نریمان. رابطه بین ساختار سرمایه و چرخه عمر شرکت. پژوهش‌های حسابداری مالی و حسابرسی ۱۳۹۵، دوره ۸، شماره ۳۰، صص ۱۳۹-۱۶۲
- (۲) ذوالفقاری مهدی، بختیاران محمدجواد و بهرام سبحانی. طراحی مدلی جهت پیشبینی بازده شاخص بورس (با تاکید بر مدل‌های ترکیبی شبکه یادگیری عمیق و مدل‌های خانواده گارچ). فصلنامه مهندسی مالی و مدیریت اوراق بهادار، ۱۳۹۸، دوره ۱۱، شماره ۴۲، صص ۱۷۱-۱۳۸.
- (۳) سعیدی حسین، محمدی شاپور. پیش‌بینی نوسانات بازده بازار با استفاده از مدل‌های ترکیبی گارچ شبکه عصبی. فصلنامه بورس اوراق بهادار، ۱۳۹۰، دوره ۴، شماره ۱۶، صص ۱۵۳-۱۷۴.
- (۴) طحاری مهرجردی محمدحسین، فاضل یزدی علی و محمد زارعی محمودآبادی. کاربرد تحلیل نا پارامتریک بازه‌ای و پنجره‌ای به‌عنوان مکملی برای ارزیابی کارایی مالی (مطالعه موردی: بانک‌های پذیرفته‌شده در بورس اوراق بهادار تهران). دانش مالی تحلیل اوراق بهادار، ۱۳۹۲، دوره ۶، شماره ۳، صص ۲۷-۴۴
- (۵) کریمی، محمد شریف، امام وردی، قدرت اله، و نیشتمان دباغی. ارزیابی و شناسایی مناسب‌ترین گزینه سرمایه‌گذاری دارایی و مالی در ایران (در بازه زمانی ۱۳۸۹-۱۳۸۰). اقتصاد مالی، ۱۳۹۲، دوره ۷، شماره ۲۵، ۱۷۷-۲۰۷
- 6) 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
- 7) 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.
- 8) Bohme, R., Christin, N., Edelman, B., Moore, M. (2015) Bitcoin: economic, technology and governance, *Journal of Economic Perspectives*, 29(2), 213-238.
- 9) Capie, F., Mills, T.C., Wood, G., 2005 Gold as a Hedge against the dollar, *J.Int.Financ., Mark., Inst. Money* 15(4), 343-352
- 10) Dyhrberg, A.H. (2016) Bitcoin, gold and the dollar – A GARCH volatility analysis, *Finance Research Letters*, <http://dx.doi.org/10.1016/j.frl.2015.10.008>.
- 11) Fatima, S. (2017). Comparison of Asymmetric Garch models with Artificial Neural Network For Stock prediction A case study. *Journal of Engineering and Applied Science*, 36(1)
- 12) 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.

- 13) 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.
- 14) Glaser, F., Zimmermann, K., Haferkorn, M., Weber, M. C., & Siering, M. (2014). Bitcoin-asset or currency? revealing users' hidden intentions. *Revealing Users' Hidden Intentions* (April 15, 2014). ECIS.
- 15) 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.
- 16) 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.
- 17) 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.
- 18) Lahmiri, S. (2017). Modeling and predicting historical volatility in exchange rate markets. *Physica A: Statistical Mechanics and its Applications*, 471, 387-395.
- 19) Kristjanpoller, W., Fadic, A., & Minutolo, M. C. (2014). Volatility forecast using hybrid neural network models. *Expert Systems with Applications*, 41(5), 2437-2442.
- 20) Markowitz, H. Portfolio selection. *The journal of finance*, 1952, 7(1), 77-91.
- 21) Monfared, S. A., & Enke, D. Volatility forecasting using a hybrid GJR-GARCH neural network model. *Procedia Computer Science*, 2014, 36, 246-253
- 22) 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).
- 23) 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.
- 24) Monfared, S. A., & Enke, D. (2014). Volatility forecasting using a hybrid GJR-GARCH neural network model. *Procedia Computer Science*, 36, 246-253.
- 25) Oakley, J., Worley, C., Yu, L., Brooks, R., & Skjellum, A. (2018, October). Unmasking Criminal Enterprises: An Analysis of Bitcoin Transactions. In *2018 13th International Conference on Malicious and Unwanted Software (MALWARE)* (pp. 161-166). IEEE.
- 26) Tully, E., Lucey, B., 2007 A power GARCH examination of the gold market, *Research in International Business and Finance*, 21(2), 316-325

27) Wang, G. (2006). A note on unit root tests with heavy-tailed GARCH errors. *Statistics & probability letters*, 76(10), 1075-1079

28) 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.Bitcoin
 - 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 Glaser et al.
 - 11 Bohme et al.
 - 12 Oakley et al.
 - 13 Capie et al.
 - 14 Dyhrberg
 - 15 Tully and Lucey
 16. Kristjanpoller & Minutolo
 17. Siddiqui et all
 - 18.Kristjanpoller, W., & Hernández
 - 19 .Fatima
 - 20 .Asymetric Garch
 - 21 .Root Mean Square Error
 - 22 .Lahmiri
 23. Generalized Error Distribution
 24. Mean Absolute Error
 - 25 .Mean Squared Error
 - 26 .Lu et all
 - 27 .Autoregressive Moving Average.
 - 28 .Autoregressive Integrated Moving Average.
 - 29 .Box –Jenkins.
 - 30 Autocorrelation.
 - 31 .Partial Autocorrelation.
 - 32 .Akaike Information Criterion.
 - 33 .Schwarz Bayesian Information Criterion.
 - 34 .Hannan–Quinn Information Criterion.

طراحی مدلی جهت پیش بینی بازده بیت کوین / بختیاران و ذوالفقاری

- 35 .Volatility
36. Nelson.
37. Ballie et al.
38. Rescaled range.
39. Geweke and Porter-Hudak.
- 40 .Jarque-Bera.
- 41 .augmented Dicky Fuller.
42. Phillips-Perron.
43. Kwiatkowski-Phillips-Schmidt-Shin.
44. LM ARCH Test.
45. Leverage effect.
- 46 Diebold-Mariano
- 47 Asymmetric Diebold-Mariano