



مقاله پژوهشی

مقایسه عملکرد سیستم های معاملات الگوریتمی مبتنی بر یادگیری ماشین در بازار رمز ارزها^۱عماد کوشان^۲، محسن صیقلی^۳، ابراهیم عباسی^۴

تاریخ دریافت: ۱۴۰۱/۰۶/۲۷

تاریخ پذیرش: ۱۴۰۲/۰۱/۲۳

چکیده

هدف از این پژوهش استفاده از مدل یادگیری جمعی برای ترکیب پیش‌بینی‌های مدل‌های جنگل تصادفی، حافظه طولانی کوتاه‌مدت و شبکه عصبی بازگشتی جهت ارائه یک سیستم معاملاتی الگوریتمی مبتنی بر آن می‌باشد. در این پژوهش یک مدل پیش‌بینی مبتنی بر مدل یادگیری ماشین جمعی ارائه شده است و عملکرد آن با هر یک از زیر الگوریتم‌ها و داده‌های واقعی مقایسه می‌شود. در این پژوهش در مرحله اول با استفاده از سه مدل یادگیری ماشین، سقف و کف قیمت بیت‌کوین پیش‌بینی شده است. در مرحله دوم، خروجی‌های مدل‌ها به عنوان متغیرهای ویژگی به مدل‌های XGboost و LightGBM جهت پیش‌بینی سقف و کف‌ها ارائه شده است. سپس در مرحله سوم خروجی‌های مرحله دوم، با الگوی دسته بندی رای گیری جمعی برای پیش‌بینی سقف و کف بعدی، ترکیب می‌شوند. داده‌های سقف و کف قیمت بیت‌کوین در تایم فریم ۱ ساعته از تاریخ ۲۰۱۸/۱/۱ الی آخر ۲۰۲۲/۶/۳۰ به عنوان متغیر هدف و ۳۱ اندیکاتور تحلیل تکنیکال به عنوان متغیر ویژگی برای سه مدل در مرحله اول استفاده شده‌اند. در نهایت مقادیر پیش‌بینی و سیستم های معاملاتی الگوریتمی با داده‌های واقعی برای ۳ مدل و مدل یادگیری جمعی معرفی شده مورد ارزیابی و مقایسه قرار گرفتند. نتایج به دست آمده نشان‌دهنده ارتقا عملکرد دقت و صحبت مدل یادگیری جمعی پیشنهاد شده در پیش‌بینی سقف و کف بیت‌کوین و همچنین، عملکرد بهتر آن نسبت به زیر الگوریتم‌ها می‌باشد.

واژگان کلیدی: معاملات الگوریتمی، پیش‌بینی سقف و کف قیمت، یادگیری ماشین جمعی، LightGBM، XGBoost**طبقه‌بندی موضوعی:** G17, B17, C53, F17, F19

۱. کد DOI مقاله: 10.22051/JFM.2024.41815.2742

۲. دانشجوی دکتری، گروه مدیریت مالی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.

۳. استادیار، گروه مدیریت، دانشکده مدیریت، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.

Email: seighaly@gmail.com

۴. استاد گروه مدیریت، دانشکده علوم اجتماعی و اقتصادی، دانشگاه الزهرا، تهران، ایران.

Email: abbasiebrahim2000@Alzahra.ac.ir

مقدمه

پیش‌بینی قیمت در بازارهای مالی یکی از مهم‌ترین عوامل موفقیت برای معامله گران و سرمایه‌گذاران می‌باشد. افزایش دقت در پیش‌بینی قیمت می‌تواند در موارد زیر به فعالین بازارهای مالی کمک کند (جیانک و همکاران، ۲۰۱۹):

- ۱- افزایش کارایی استراتژی‌های معامله‌گری
- ۲- سرمایه‌گذاران می‌توانند بر اساس نتایج پیش‌بینی به دنبال پوشش ریسک خود باشند.
- ۳- سفته‌بازان و آربیتراژگران می‌توانند از نتایج پیش‌بینی خود بازدهی خود را افزایش و ریسک را کاهش دهند.
- ۴- می‌توانند با پیش‌بینی شاخص‌های مهم در مورد بازارهای مالی به طور کلی، اظهار نظر نمایند. بنابراین، پیش‌بینی قیمت برای فعالین بازارهای مالی، اهمیت و ضرورت ویژه‌ای دارد. در بین بازارهای مالی، بازار رمز ارزها^۱ با توجه به رشد خیره‌کننده آن‌ها در سال‌های ۲۰۱۵ تا ۲۰۱۷ و ۲۰۱۹ تا ۲۰۲۱ توانسته نظر سرمایه‌گذاران و فعالین را به خود جلب کند. بیت‌کوین به عنوان بزرگ‌ترین رمز ارز، یک پول دیجیتالی است که توسط ناکاموتو در سال ۲۰۰۸ ارائه شد. این رمز ارز از فناوری بلاکچین^۲ و رمزنگاری^۳ استفاده کرده است تا افراد بتوانند همتأ به همتا به صورت امن تراکنش مالی انجام دهند (ناکاماتو، ۲۰۰۸). از دلایل مهم رشد بیت‌کوین در سال‌های ۲۰۱۹ تا ۲۰۲۱، می‌توان به اثر هاوینگ^۴ (نصف شدن جایزه شبکه بیت‌کوین) در سال ۲۰۲۰، پاندمی کرونا و سیاست‌های انساطی فدرال رزرو و همچنین حمایت شرکت‌ها و سازمان‌های بزرگ در دنیا اشاره کرد. پیش‌بینی قیمت بیت‌کوین به عنوان بزرگ‌ترین رمز ارز در این بازار می‌تواند به شکل نماینده عمل کند چرا که همبستگی سایر رمز ارزها (آلتكوین) با بیت‌کوین بالاست. در نتیجه پیش‌بینی قیمت بیت‌کوین می‌تواند برای فعالین در بازارهای مالی بین‌المللی با هدف سپر تورمی، را می‌توان اهمیت و ضرورت این پژوهش دانست.

در این پژوهش، به دنبال پیش‌بینی قیمت بیت‌کوین به عنوان نماینده بازار رمز ارزها با استفاده از مدل‌های یادگیری ماشین و سپس، ارائه سیستم معاملاتی مبتنی بر آن هستیم. گوپتا و نیبن^۵ در پژوهشی نشان دادند که مدل‌های سری زمانی به طور خاص مدل میانگین متحرک وزنی^۶ و ARIMA در پیش‌بینی قیمت بیت‌کوین نسبت به مدل‌های یادگیری ماشین یا یادگیری ماشین عمیق عملکرد بهتری در پیش قیمت یک روز دارند. همچنین، توانستند در بهترین حالت ۸۶ درصد دقت را ارائه کنند. البته پژوهش‌هایی نشان دادند مدل‌های یادگیری ماشین، با توجه به غلبه بر محدودیت‌های خطی مدل‌های کلاسیک توانسته‌اند دقت پیش‌بینی را افزایش دهند (فقیهی نژاد و مینایی، ۱۳۹۷). این پژوهش، به جای

-
1. Cryptocurrencies
 2. Blockchain
 3. Cryptography
 4. Halving
 5. Gupta and Nain
 6. Weighted Moving Average

رویکرد سری زمانی و پیش‌بینی یک داده بعد به دنبال پیش کف و سقف بعدی برای بیت‌کوین در تایم فریم ۱ ساعته است. با رویکرد گسسته و دسته‌بندی سقف یا کف می‌توان دقت مدل‌های یادگیری ماشین را در پیش‌بینی ارتقا داد.

بنابراین، هدف این پژوهش پیش‌بینی سقف‌ها و کف‌های بیت‌کوین با استفاده از مدل‌های یادگیری ماشین نظارت شده می‌باشد. مدل پیشنهادی در این پژوهش سه مرحله اصلی دارد. در مرحله اول، سقف‌وکف‌های قیمت بیت‌کوین با استفاده از مدل‌های جنگل تصادفی^۱، حافظه طولانی کوتاه‌مدت^۲ و شبکه عصبی بازگشتی^۳ پیش‌بینی می‌شوند. در مرحله دوم، نتیجه حاصله به عنوان ورودی به مدل‌های XGBoost^۴ و LightGBM^۵ ارائه می‌شود و نتایج این دو مدل با استفاده از یادگیری جمعی^۶ رای گیری^۷ ترکیب شده و نتیجه پیش‌بینی نهایی قابل مقایسه با داده واقعی می‌باشد. در گام آخر، بر اساس هر یک از مدل‌های RF، LSTM، RNN و یادگیری جمعی پیشنهادی یک سیستم معاملاتی برای بازه زمانی داده‌های تست اجرا و ارزیابی می‌شوند. عملکرد این سیستم‌های معاملاتی به طور مجزا بررسی و با یکدیگر مقایسه می‌شوند. این مراحل به صورت دقیق در بخش‌های بعدی پژوهش توضیح داده شده است.

مبانی نظری و مروری بر پیشینه پژوهش:

پیش‌بینی قیمت دارایی‌های مالی، یکی از موضوعات مهم برای فعالین، سرمایه‌گذاران، معامله‌گران و آربیتراژ‌گران در بازارهای مالی است. به طور کلی، روش‌های پیش‌بینی قیمت در بازارهای مالی را می‌توان به دو دسته اصلی کلاسیک و هوشمند تقسیم‌بندی کرد. در روش‌های کلاسیک فرض بر این است مقادیر آینده با متغیرهای توضیح‌دهنده که می‌تواند عوامل موثر بر قیمت یا خود قیمت با وقته زمانی باشد پیش‌بینی می‌شوند. در این مدل‌های نیاز است رابطه میان متغیرهای توضیح‌دهنده و وابسته مشخص و با استفاده از پیش آزمون‌ها داده‌ها را با فروض مدل‌ها تطبیق داده تا نتایج مطلوب دست پیدا کند. در مقابل روش‌های هوشمند هستند که از یادگیری ماشین استفاده می‌کنند. در این رویکرد، رابطه از قبل مشخص نیست و این الگوریتم‌ها به دنبال کشف یک رابطه ریاضی هستند.

یادگیری ماشین حوزه مطالعاتی است که به رایانه‌ها توانایی یادگیری بدون برنامه‌ریزی آشکار روی می‌دهد (ساموئل، ۱۹۵۹). در حال حاضر، یادگیری ماشین به سه دسته اصلی؛ یادگیری نظارت شده^۸، نظارت نشده^۹ و تقویتی^{۱۰} تقسیم‌بندی می‌شود. یادگیری ماشین نظارت شده، به دنبال ارتباط بین مقادیر

-
1. Random Forest (RF)
 2. Long-Short Term Memory (LSTM)
 3. Recurrent Neural Network (RNN)
 4. Extreme Gradient Boosting (XGBoost)
 5. Light Gradient Boosting Machine (LightGBM)
 6. Ensemble learning
 7. Voting ensemble classifier
 8. Supervised Learning
 9. Unsupervised learning
 10. Reinforcement learning

متغیرهای ویژگی با متغیر هدف است. در نتیجه، از این مدل‌ها بیشتر در مسائل پیش‌بینی استفاده می‌شود. دو نوع اصلی یادگیری ماشین نظارت شده؛ طبقه‌بندی و رگرسیون مطرح می‌باشد. با توجه با اینکه پژوهش حاضر به دنبال پیش‌بینی بازار با رویکرد گستته است، از الگوریتم‌های یادگیری ماشین طبقه‌بندی استفاده شده است. می‌توان گفت با توجه به اینکه در این پژوهش هدف ۰ (در مسیر کف بازار) و ۱ (در مسیر سقف) بازار است، یک بردار هدف دو دویی وجود دارد که با استفاده از مدل‌های LSTM و RNN پیش‌بینی می‌شود. در مورد نحوه پیش‌بینی، در قسمت روش پژوهش به طور کامل توضیح داده شده است.

مرور پیشینه پژوهش نشان می‌دهد، استفاده از الگوریتم‌های یادگیری ماشین توانسته به صورت معنی داری به دسته‌بندی و پیش‌بینی قیمت در بازارهای مالی کمک کند (тан^۱ و همکاران^۲، متور^۳ و همکاران^۴). در حالی که مدل‌های یادگیری ماشین در پیش‌بینی بازارهای مالی توانسته توجه بسیاری از فعالین را به خود جذب کند، در مطالعات اخیر، مدل‌های متنوع یادگیری جمعی توانسته اند دقت پیش‌بینی افزایش دهند (نتی^۵ و همکاران^۶). فقیهی نژاد و مینایی (۱۳۹۷) پژوهش‌هایی که در حوزه پیش‌بینی قیمت با استفاده از یادگیری ماشین (مدل‌های هوشمند) انجام شده‌اند را به سه گروه تقسیم کرده اند؛ گروه اول، پژوهش‌هایی هستند که تنها از یک مدل یا الگوریتم استفاده برای پیش‌بینی استفاده می‌کنند. گروه دوم، از چند مدل به صورت ترکیبی استفاده می‌کنند. گروه سوم، استفاده از مدل‌های یادگیری جمعی برای تجمعی خروجی‌ها مدل‌ها استفاده می‌نمایند. در ادامه پژوهش‌هایی که از مدل‌های یادگیری جمعی برای پیش‌بینی قیمت استفاده کردند، مرور می‌شوند.

يانگ^۷ و همکاران (۲۰۲۱)، از مدل‌های XGBoost و LightGBM برای پیش‌بینی قیمت سهام استفاده کردند. نتیجه این پژوهش، عملکرد بهتر مدل ترکیبی از هر یک از مدل‌های به صورت مجزا در پیش‌بینی قیمت سهام را نشان داد.

لى و پن^۸ (۲۰۲۲)، در پژوهشی یک مدل نوین یادگیری عمیق را برای پیش‌بینی حرکت قیمت سهام پیشنهاد دادند. این مدل از مدل یادگیری جمعی برای ترکیب دو شبکه عصبی بازگشتی استفاده کرده است. در این پژوهش از داده شاخص S&P 500 استفاده شده است. نتیجه این پژوهش نشان دهنده کاهش ۵۷,۷٪ میانگین محدود خط و افزایش شاخص‌ها صحت به میزان ۴۰٪، پوشش به اندازه ۵۰٪ و F1 به اندازه ۴۴,۷۸٪ شده است.

سان^۹ و همکاران (۲۰۲۰)، در پژوهشی با استفاده از GBDT و LightGBM روند بازار رمز ارزها را پیش‌بینی کردند. برای این پیش‌بینی از ۴۲ نوع رمز ارز با شاخص‌های اقتصادی کلیدی استفاده شده است. نتیجه پژوهش نشان دهنده عملکرد پایدار و بهتر LightGBM نسبت به سایر مدل‌ها می‌باشد.

1. Tan

2. Mathur

3. Nti

4. Yang

5. Li and Pan

6. Sun

بورگس و نوس^۱ (۲۰۲۰)، یک سیستم مبتنی بر یادگیری ماشینی را برای توسعه یک استراتژی سرمایه‌گذاری با قابلیت معامله در بازارهای رمز ارزها پیشنهاد کردند. آن‌ها از مدل‌های رگرسیون لجستیک، RF، دسته‌بندی کننده بردار پشتیبان و تقویت درخت گرادیان برای پیش‌بینی با کمک شاخص‌های تحلیل تکنیکال به عنوان متغیرهای ویژگی استفاده کردند. آنها نشان دادند که صرف نظر از روش نمونه‌گیری مجدد مورد استفاده، همه الگوریتم‌های یادگیری بهتر از استراتژی خرید و نگه داشتن (B&H) در اکثریت قریب به اتفاق ۱۰۰ بازار مورد آزمایش قرار گرفتند.

لامیری و بیکریوس^۲ (۲۰۱۹)، از سه مدل متفاوت LSTM، GRNN و نزدیک‌ترین همسایه برای بررسی رفتار غیر خطی بیت‌کوین استفاده کردند. مطابق با نتیجه یون و همکاران (۲۰۲۱) آن‌ها دریافتند که LSTM خطای کمتری نسبت به سایر روش‌ها دارد و می‌تواند الگوهای را بهتر تشخیص دهد. ژانگ و همکاران^۳ (۲۰۱۸)، مدلی را با استفاده از جنگلهای تصادفی، یادگیری عدم تعادل، انتخاب ویژگی و برش برای پیش‌بینی حرکت قیمت سهام و فاصله نرخ رشد (یا کاهش) آن پیشنهاد کردند. این مدل با استفاده از بیش از ۷۰ شاخص تحلیل تکنیکال به عنوان ورودی، اهداف پیش‌بینی را در ۴ کلاس می‌توان طبقه‌بندی کرد: بالا، پایین، مسطح و ناشناخته. این مدل با استفاده از بیش از ۴۰۰ سهم در بازار شیزئن ارزیابی شد. نتایج نشان دادند که از نظر دقت و بازده در هر معامله مدل پیشنهادی این پژوهش از شبکه عصبی مصنوعی، ماشین بردار پشتیبان^۴ و کی-نزدیک‌ترین همسایه‌ها^۵ بهتر عمل می‌کند.

آگرووال^۶ و همکاران (۲۰۲۰)، با هدف کشف ماهیت قیمت بیت‌کوین و پیش‌بینی آن از مدل‌های یادگیری ماشین استفاده کردند. در این پژوهش از مدل یادگیری جمعی (CEEMD) استفاده شده است. قیمت روزانه بیت‌کوین از سال ۲۰۱۲ الی ۲۰۱۸ مورد استفاده قرار گرفته است تا به سه قسمت؛ کوتاه، میان و بلندمدت تقسیم شوند. این پژوهش از مدل ماشین بردار پشتیبان استفاده کرده است که می‌تواند برای ۵ گام کوتاه‌مدت بیت‌کوین را پیش‌بینی نماید.

دنیز^۷ و همکاران (۲۰۱۹)، در پژوهشی در گام اول مهندسی ویژگی و الگوریتم‌های متفاوت انتخاب متغیر ویژگی برای پیش‌بینی قیمت بیت‌کوین پیش‌بینی اجرا نمودند. سپس از مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و مدل‌های یادگیری جمعی مبتنی بر شبکه عصبی بازگشتی و خوش‌بندی میانگین K تایی برای پیش‌بینی قیمت بیت‌کوین استفاده کردند. نتیجه حاصل از این پژوهش افزایش ۱۰ درصد دقت پیش‌بینی نتایج پژوهش‌های قبلی است.

-
1. Borges and Neves
 2. Lahmiri and Bekiros
 3. Zhang et al
 4. Support vector machines - SVMs
 5. k-nearest neighbors' algorithm
 6. Aggarwal
 7. Dennys

نتی^۱ و همکاران (۲۰۲۰)، یک پژوهش تحلیلی مقایسه‌ای گستردۀ از مدل‌های یادگیری جمعی اعم از؛ Bagging، Boosting و Stacking انجام دادند. مدل‌های درخت تصمیم گیری، ماشین بردار پشتیبان، شبکه عصبی با ۲۵ حالت مختلف با یادگیری جمعی ترکیب شدند. این پژوهش از سال ۲۰۱۲ الی ۲۰۱۸ شاخص‌های بورس غنا، ژوهانسبورگ، بمبئی و نیویورک با استفاده از مدل‌ها پیش‌بینی نموده و عملکرد آن‌ها را مورد مقایسه قرار داده است. نتیجه این پژوهش نشان می‌دهد مدل‌های Blending و Stacking دقیق‌تر و خطای کمتری نسبت به مدل‌های boosting و bagging دارد.

جاکارت و همکاران^۲ (۲۰۲۱)، پیش‌بینی پذیری بازار بیت‌کوین را در افق‌های پیش‌بینی ۱ تا ۶۰ دقیقه تجزیه و تحلیل کردند. آن‌ها دریافتند که RNN و طبقه‌بندی Gboost برای پیش‌بینی بازار عملکرد قابل قبولی دارند. آن‌ها از متغیرهای ویژگی منتنوعی شامل تحلیل تکنیکال، داده‌های بلاکچین، احساسات و غیره استفاده کردند. به علاوه، قابلیت پیش‌بینی در افق‌های طولانی تر افزایش می‌یابد.

یون^۳ و همکاران (۲۰۲۱)، یک مدل ترکیبی از XGBoost و الگوریتم ژنتیک با یک فرآیند مهندسی ویژگی گستردۀ بر روی بیش از ۶۰ شاخص تحلیل تکنیکال برای پیش‌بینی‌های بازار سهام پیشنهاد کردند. مدل ترکیبی آنها می‌تواند از نظر عملکرد و تفسیرپذیری بهتر از مدل‌های LSTM عمل کند.

نتی آدکویا و ویوری^۴ (۲۰۲۰) یک طبقه‌بندی گروه همگن^۵ بر اساس الگوریتم ژنتیک برای انتخاب ویژگی‌ها و بهینه‌سازی پارامترهای SVM برای پیش‌بینی حرکت قیمت ۱۰ روزه در بورس غنا پیشنهاد کرد. آنها از روش گروه رای اکثریت ساده برای ترکیب نتایج حاصل از ۱۵ مدل بردار ماشین پشتیبان مختلف با استفاده از ۱۴ شاخص تحلیل تکنیکال به عنوان ورودی استفاده کردند. نتایج تجربی آنها نشان داد مجموعه آنها دقیق پیش‌بینی بالاتری از حرکت قیمت سهام در مقایسه با درخت تصمیم، جنگل تصادفی و شبکه عصبی دارد.

آمپوما و همکاران^۶ (۲۰۲۰) اثربخشی مدل‌های مختلف مجموعه مبتنی بر درخت از جمله جنگل تصادفی، Extra Trees Classifier، AdaBoost، Bagging، XGBoost و Voting Classifier را در پیش‌بینی جهت حرکت قیمت سهام مقایسه کرد. برای این مطالعه از هشت داده مختلف سهام از سه بورس اوراق بهادار NYSE و NASDAQ استفاده شد. آنها از تجزیه و تحلیل اجزای اصلی برای انتخاب ویژگی ۴۵ ورودی شامل ۴۰ شاخص تحلیل تکنیکال استفاده کردند. نتایج تجربی نشان داد طبقه‌بندی‌کننده Extra Trees نسبت به سایر مدل‌ها، در تمام رتبه‌بندی‌ها عملکرد بهتری داشت.

تا^۷ و همکاران (۲۰۲۰) پرتفویی با استفاده از شبکه عصبی LSTM و سه روش بهینه‌سازی پرتفوی، به عنوان مثال؛ روش هم وزن شبیه‌سازی مونت کارلو و مدل MV ایجاد کردند. همچنین، آنها از رگرسیون خطی و SVM به عنوان مقایسه در فرآیند انتخاب سهام استفاده کردند. نتایج تجربی نشان داد که شبکه

-
1. Nti
 2. Jaquart
 3. Yun
 4. Nti, Adekoya, and Weyori
 5. Homogeneous Ensemble Classifier
 6. Ampomah.
 7. Ta

عصبی LSTM دارای دقت پیش‌بینی بالاتری نسبت به رگرسیون خطی و SVM است و پرتفوهای ساخته شده آن بهتر از سایرین عمل می‌کند. این مدل‌ها روش‌های مختلفی را برای انتخاب سهام اعمال می‌کنند، سپس، مدل‌های بهینه‌سازی سبد سهام را با سهام منتخب برای سرمایه‌گذاری تجاری ایجاد می‌کنند. این روش‌ها جهت امیدوار کننده‌ای برای ساخت مدل‌های پرتفو را در عمل نشان می‌دهند. با این حال، مدل‌های کلاسیک بهینه‌سازی اوراق بهادر اغلب برای سرمایه‌گذاری عملی کوتاه‌مدت نامناسب هستند. بنابراین، کشف رویکرد کارآمدتر برای ترکیب نتایج پیش‌بینی بازده با مدل‌های بهینه‌سازی پرتفو مهم است.

کیم^۱ (۲۰۲۱)، یک سیستم معاملاتی تطبیقی جدید ایجاد کردند که در آن از یادگیری ماشینی و آزمایش برگشتی^۲ برای بازار اوراق قرضه استفاده می‌کند. که در آن یک مدل پیش‌بینی که اسپرد بین اوراق خزانه ۱۰ و ۳ ساله را پیش‌بینی می‌کند پیشنهاد شده است. متعاقباً برای تأیید عملکرد مدل پیش‌بینی، از آزمون برگشتی استفاده می‌شود. که AdaBoost از سایر مدل‌های پیش‌بینی بهتر عمل می‌کند. علاوه بر این، زمانی که آزمون برگشتی بر اساس نتایج مدل‌های پیش‌بینی کننده اعمال شد، تا ۵۴/۲ درصد در بازده سرمایه‌گذاری طی ۶ ماه کسب شد.

فقیهی نژاد و مینایی^۳ (۲۰۲۱)، مدلی برای پیش‌بینی بازار سهام با استفاده از مدل‌های هوشمند و یادگیری ماشین ارائه کردند. در این پژوهش برای افزایش دقت از مدلی بر مبنای الگوریتم یادگیری جمعی با مدل‌های پایه شبکه عصبی استفاده شده است. نتایج این پژوهش نشان داد اولاً، پیش‌بینی رفتار بازار سهام با وجود ماهیت نوسانی و ناپایدار آن امکان‌پذیر است. ثانیاً، مدل پیشنهادی این پژوهش در مقایسه با سایر روش‌ها با دقت بیشتری می‌تواند بر نوسان‌های بازار غلبه کند.

عباسی و همکاران (۲۰۲۰)، عملکرد استراتژی‌های مبتنی بر اندیکاتورهای تحلیل تکنیکال را با استراتژی خرید و نگهداری مقایسه کردند و به این نتیجه رسیدند که استراتژی‌های مبتنی بر تحلیل تکنیکال می‌تواند بازدهی بهتری نسبت به خرید و نگهداری داشته باشد. بنابراین، استفاده از اندیکاتورها می‌تواند در پیش‌بینی کمک کننده باشد.

سهرابی و همکاران (۱۴۰۱)، رویکرد های جنگل تصادفی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی بازگشتی برای پیش‌بینی شاخص کل بورس اوراق بهادر تهران در دوره ۱۳۹۲ تا ۱۳۹۹ مورد استفاده قرار دادند. نتایج پیش‌بینی دوره‌های ۱، ۳ و ۶ روزه برای دوره خارج از نمونه نشان می‌دهد روش یادگیری ماشین مبتنی بر شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت (LSTM) در مقایسه با سایر مدل‌های مورد بررسی نتیجه بهتری داشته است.

بشیری و پاریاب (۱۳۹۹)، عملکرد مدل‌های جنگل تصادفی، بردار پشتیبان، گرادیان تقویتی و شبکه عصبی چند لایه پرسپترون را برای پیش‌بینی قیمت بیت‌کوین با استفاده از داده ۹ رمز ارز دیگر مورد مقایسه قرار دادند. نتیجه این پژوهش نشان دهنده دقت بیشتر مدل گرادیان تقویتی است.

-
1. Misuk Kim
 2. Back-testing
 3. Faghihi and Minaei



قریانی و همکاران (۱۴۰۱)، برای پیش‌بینی تغییرات قیمتی بیتکوین با استفاده از الگوریتم‌های یادگیری ماشین همراه با استفاده از داده‌های تحلیل احساسات مردم نسبت به افراد مشهور مانند ایلان ماسک در شبکه‌های اجتماعی توییتر، ردیت و تلگرام مدل ارائه کردند. در این پژوهش الگوریتم xgboost با رکورد دقت بدست آمده ۸۸ درصدی در پیش‌بینی روند تغییرات قیمت بیتکوین عملکرد عالی را نشان داد. برای جمع‌بندی، بر اساس پژوهش مروری کروانجو و آکای، بسیاری از پژوهش‌ها به دنبال مقایسه مدل‌های آماری و یادگیری ماشین بوده اند که به طور کلی، مدل‌های یادگیری ماشین در مقایسه با مدل‌های آماری توانسته اند عملکرد بهتری را نشان بدهند (کروانجو و آکای، ۲۰۲۰). حال با توجه به جذابیت پیش‌بینی قیمت رمز ارزها (به ویژه، بیتکوین) برای فعالین، بسیاری دیگر از پژوهش‌ها به مقایسه عملکرد مدل‌های یادگیری ماشین و یا ترکیب آن‌ها در دقت پیش‌بینی پرداخته‌اند. در مطالعاتی که از یادگیری جمعی استفاده شده است، این رویکرد توانسته است عملکرد و دقت پیش‌بینی قیمت را افزایش دهد. لازم به ذکر است پژوهش‌های فوق بازارهای مالی متفاوتی مانند؛ بازار سهام^۱، اوراق قرضه^۲، شاخص‌های بورس، رمز ارزها و کالا مورد بررسی قرار گرفته است که به تقویت نتیجه‌گیری برتری یادگیری جمعی منجر می‌شود.

جدول ۱. دسته بندی پژوهش‌های مرتبط با پیش‌بینی بازارهای مالی با استفاده از یادگیری ماشین

ردیف	نام دسته	پژوهش‌ها	چکیده	نقاط قابل بهبود
۱	پیش‌بینی بر اساس ترکیب مدل‌های یادگیری ماشین (استفاده از یادگیری جمعی)	امپوما ^۳ و همکاران (۲۰۲۰) فقیهی نژاد و بیدگلی (۲۰۲۱) لیوریس ^۴ و همکاران (۲۰۲۰) یه ^۵ و همکاران (۲۰۲۲) ادکویا و ویوری ^۶ (۲۰۱۹) یانگ ^۷ و همکاران (۲۰۲۱) ادکویا و ویوری ^۸ (۲۰۲۰) دنیس ^۹ و همکاران (۲۰۱۹) آگاروال ^{۱۰} و همکاران (۲۰۲۰) لی و پن ^{۱۱} (۲۰۲۲)	در این پژوهش‌ها، مدل‌های یادگیری ماشین با استفاده از یادگیری جمعی با هم ترکیب شده‌اند. نشان داده شده است که یادگیری جمعی عملکرد بهتری نسبت به هر یک از مدل‌های پیش‌بینی به صورت جداگانه دارد.	پیش‌بینی کف و سقف نمودار می‌تواند نسبت به بازدهی با خود قیمت عملکرد بهتری داشته باشد.

1. Kervancı and F. Akay
2. Stock
3. Bonds
4. Ampomah
5. Livieris
6. Ye
7. Adekoya, Weyori
- 8 .Yang
9. Adekoya, Weyori
10. Dennys
11. Aggarwal
12. Li and Pan

ردیف	نام دسته	پژوهش‌ها	چکیده	نقاط قابل بهبود
۲	مقایسه عملکرد مدل‌های یادگیری ماشین در پیش‌بینی قیمت	سان ^۱ و همکاران (۲۰۲۰) ژیانگ ^۲ و همکاران (۲۰۲۰) یون ^۳ و همکاران (۲۰۲۱) ریمن ^۴ و همکاران (۲۰۲۰) مانچاندا و آگاروال ^۵ (۲۰۲۱) لامیری و بیکریوس ^۶ (۲۰۱۹) جاکارت و همکاران ^۷ (۲۰۲۱) بورگس و نویس ^۸ (۲۰۲۰) ناگولا و الکساکیس ^۹ (۲۰۲۲) جی ^{۱۰} و همکاران (۲۰۱۹) تا ^{۱۱} و همکاران (۲۰۲۰)	در این پژوهش‌ها، عملکرد مدل‌های مختلف یادگیری ماشین با هم مقایسه شده است.	پیش‌بینی کف و سقف نمودار می‌تواند نسبت به بازدهی یا خود قیمت عملکرد بهتری داشته باشد.

شکاف مطالعاتی پیشنهادی این پژوهش، رویکرد مدل‌سازی داده‌های قیمت می‌باشد. در بسیاری از پژوهش‌ها به دنبال پیش‌بینی عدد قیمت یا به دلایل مانایی و غیره، عدد بازدهی هستند. در صورتی که این رویکرد می‌تواند دقت پیش‌بینی را کاهش دهد، با اینکه قیمت یک داده سری زمانی^{۱۲} است، می‌توان به شکل گستته به آن نگاه کرد. به معنی آن که، به جای اینکه پیش‌بینی قیمت یا بازدهی آن می‌باشد به دنبال پیش‌بینی وضعیت سقف یا کف بود. اینکه بدانیم در مسیر ساختن سقف قیمتی یا کف قیمتی هستیم، در صورتی که باعث افزایش دقت و کارایی مدل‌های پیش‌بینی شود، می‌توان بر اساس آن معاملات الگوریتمی مطمئن‌تری طراحی و پیاده‌سازی کرد. بنابراین، این پژوهش به دنبال پیش‌بینی وضعیت سقف یا کف قیمتی بر اساس مدل‌های یادگیری ماشین می‌باشد. در ادامه، روش پژوهش و چگونگی پیش‌بینی وضعیت سقف و کف مورد استفاده در این پژوهش ارائه می‌شود.

سؤالات پژوهش

با توجه به هدف این پژوهش که به دنبال پیش‌بینی سقف یا کف قیمت بیت‌کوین با استفاده از مدل‌های یادگیری ماشین است، سوالات این پژوهش را می‌توان به شکل زیر ارائه نمود:

1. Sun
2. Jiang
3. Yun
4. Rahman
5. Manchanda and Aggarwal
6. Lahmiri and Bekiros
7. Jaquart
8. Borges and Neves
9. Nagula and Alexakis
10. Ji
11. Ta
12. Time Series

- ۱- عملکرد سیستم معاملاتی هوشمند مبتنی بر مدل های پیش بینی جنگل تصادفی، یادگیری حافظه بلند و کوتاه مدت، شبکه عصبی بازگشتی و یادگیری جمعی در مقایسه با داده واقعی و استراتژی خرید و نگهداری^۱ چگونه است؟
- ۲- میزان دقت و صحت یادگیری ماشین جمعی در پیش بینی سقف و کف های بیت کوین چقدر است؟
- ۳- آیا میزان دقت و صحت پیش بینی سقف و کف های بیت کوین با استفاده از یادگیری ماشین جمعی نسبت به زیر الگوریتم ها بیشتر است؟

روش شناسی پژوهش

با توجه به اینکه بازار مالی هدف در این پژوهش بازار رمز ارزها (بیت کوین) می باشد، استفاده از پایگاه داده معتبر اهمیت دارد. در این پژوهش داده های قیمت کندل ها (OHLCV) بیت کوین در تایم فریم ۱ ساعته به عنوان بزرگترین رمز ارز به عنوان نماینده این بازار انتخاب شده است. برای استخراج این داده از مژول پایتونی Historic-Crypto که داده ها را از API صرافی CoinBase Pro استخراج می کند، استفاده شده است. بازار رمز ارزها با توجه به نصف شدن پاداش استخراج، رفتار سیکلی به صورت ۴ ساله دارد. بنابراین، از کل داده های بیت کوین که از سال ۲۰۱۰ در درسترس است، بازه زمانی ۲۰۱۸ الی ۲۰۲۲ انتخاب شده است. در سال ۲۰۱۸ بیت کوین بازاری رکودی و سپس نزولی، را تجربه کرده است. در سال های ۲۰۱۹ الی ۲۰۲۱ نیز یک روند صعودی با توجه پاندمی کرونا و نصف شدن جایزه در سال ۲۰۲۰ را تجربه کرده است. در سال ۲۰۲۲ نیز یک روند رکودی و نزولی که می توان گفت برگشت به سال ۲۰۱۸ است که در نتیجه نشان می دهد نمونه حاضر کلیه فازهای سیکلی را توضیح می دهد. ۷۰ درصد ابتدایی داده ها به عنوان داده های آموزشی به مدل داده می شود. ۲۰ درصد داده ها به عنوان داده های اعتبار سنجی در نظر گرفته شده و ۱۰ درصد انتهایی داده ها به عنوان داده های تست به مدل داده می شوند.

با استفاده از زبان برنامه نویسی پایتون و مژول ها معتبر در آن این پژوهش انجام شده است. در بستر Google Colab با توجه به اشتراک گذاری GPU و همچنین، از کتابخانه های `ta`, `Pandas`, `numpy`, `Scipy` و `sklearn`, `tensorflow`, `freqtrade` استفاده شده است. برای ارزیابی عملکرد استراتژی ها از چارچوب پایتونی `freqtrade` استفاده شده است.

متغیرهای این پژوهش به دو دسته اصلی تقسیم می شوند. متغیر هدف، متغیری است که به دنبال پیش بینی آن هستیم، متغیر هدف در این پژوهش سقف یا کف (۱ یا ۰) است که با استفاده از اندیکاتور Awesome Oscillator (AO) از قیمت بسته شدن کندل های استفاده شده است. سایر متغیرهای اندیکاتور های تحلیل تکنیکال به عنوان متغیر ویژگی، برای پیش بینی سقف یا کف های قیمتی می باشند. لازم به ذکر است برای انتخاب این متغیرها از کتابخانه های موجود همبستگی بالغ بر ۱۵۰ اندیکاتور و اسیلاتور با متغیر هدف مورد بررسی قرار گرفته و اندیکاتور های (عددی) که همبستگی پیرسون بالای ۰/۰۵ p_value و با ۷۰ داشتند، به عنوان متغیر ویژگی انتخاب شده اند. در ادامه لیست این

اندیکاتورها معرفی می‌شود. پس از آن داده‌های یادگیری به دنبال کشف ارتباط بین لیست اندیکاتورها و متغیر هدف یعنی سقف و کف‌ها با استفاده از مدل‌های RF و LSTM می‌باشد. اعداد مربوط به اندیکاتور و اسیلاتور با تقسیم شدن به عدد قیمت بسته شدن نرمال شده‌اند تا در یک مقیاس باشند. همان‌طوری که گفته شده ۷۰ درصد داده به عنوان داده یادگیری و ۳۰ درصد ما بقی جهت اجرای مراحل بعدی در نظر گرفته شده است. لیست اندیکاتور و اسیلاتورهای مورد استفاده در این پژوهش، به شرح ذیل می‌باشد:

جدول ۲. لیست متغیرهای ویژگی مورد استفاده در مرحله اول

نام متغیر	نام در مدل	نام متغیر	نام در مدل
میانگین حجم	'volume_sma_em'	حجم (شاخص جریان پول)	volume_mfi
KCP نوسان	'volatility_kcp'	BBP نوسان	'volatility_bbp'
MACD روند	'trend_macd'	DCP نوسان	'volatility_dcp'
ADX روند	'trend_adx_pos'	اختلاف روند MACD	'trend_macd_diff'
VOREXT اختلاف روند	'trend_vortex_ind_diff'	VORTEX روند	'trend_vortex_ind_pos'
AROON روند	'trend_aroon_up'	CCI روند	'trend_cci'
RSI جهش	'momentum_rsi'	STC روند	'trend_stc'
UO جهش	'momentum_uo'	TSI جهش	'momentum_tsi'
STOCH SIGNAL جهش	'momentum_stoch_signal'	STOCHAS'IC جهش	'momentum_stoch'
AO جهش	'momentum_ao'	WR جهش	'momentum_wr'
AO	'ao'	ROC جهش	'momentum_roc'
بالا میانگین متحرک ۱۰ تابی	'aboveEMA10'	شاخص قدرت نسبی	'RSI'
بالا میانگین متحرک ۲۰ تابی	'aboveEMA20'	بالا میانگین متحرک ۱۵ تابی	'aboveEMA15'
بالا میانگین متحرک ۴۰ تابی	'aboveEMA40'	بالا میانگین متحرک ۳۰ تابی	'aboveEMA30'
بالا میانگین متحرک ۶۰ تابی	'aboveEMA60'	بالا میانگین متحرک ۵۰ تابی	'aboveEMA50'

در لیست بالا اندیکاتورهای تحلیل تکنیکال مربوط به حجم معاملات، نوسان پذیری قیمت، مبتنی بر روند، جهش‌های قیمتی و همچنین، اندیکاتورهای باینری معرفی شده است. همان‌طور که گفته شد، این اندیکاتورها رابطه معنی‌داری با متغیر هدف (سقف یا کف) دارند. لازم به ذکر است که اندیکاتورهای باینری از قسمت مهندسی ویژگی این پژوهش به این لیست اضافه شده‌اند. زیرا این متغیرها در بهبود دقت مدل‌ها توانسته‌اند نقش به سزاگی داشته باشند. برای توضیح بیشتر اندیکاتورهای باینری، اندیکاتور بالای (10) EMA را در نظر بگیرید که خود یک متغیر باینری ۰ و ۱ می‌باشد. در صورتی که قیمت بالای میانگین متحرک نمایی ۱۰ تابی باشد، عدد ۱ و اگر کمتر از آن باشد، عدد صفر را به خود اختصاص می‌دهد.

مراحل اجرای مدل به صورت کلی به شرح ذیل می‌باشد:

مرحله ۱ – داده‌های سقف و کف بیت‌کوین به عنوان متغیر هدف با استفاده از مدل‌های جنگل تصادفی، حافظه طولانی کوتاه‌مدت و شبکه عصبی بازگشتی با متغیرهای ویژگی جدول (۱)، پیش‌بینی می‌شوند. خروجی حاصل از این مرحله پیش‌بینی های سقف و کف هر یک از مدل‌ها به همراه امتیاز آن‌ها می‌باشد.

مرحله ۲ – خروجی مرحله اول (پیش‌بینی سقف و کف‌ها به همراه امتیاز آن‌ها) به عنوان متغیر ویژگی به همراه سقف‌ها و کف‌ها به عنوان هدف به مدل‌های XGBoost و LightGBM برای یادگیری ارائه می‌شوند.

مرحله ۳- خروجی‌های حاصل از مرحله دوم به استفاده از الگوریتم یادگیری جمعی رأی‌گیری تا نتیجه پیش‌بینی نهایی ثبت شده و با داده واقعی مقایسه می‌شود.

مرحله ۴- گام آخر استفاده از نتایج مدل‌ها پیش‌بینی LSTM، RNN، RF و یادگیری جمعی پیشنهادی جهت سیگنال خرید و فروش در بازار رمز ارزها و مقایسه عملکرد استراتژی معاملاتی مبتنی بر آن‌ها با سیستم معاملاتی مبتنی بر داده‌های واقعی سقف و کف بیت‌کوین می‌باشد.

همان‌طور که در بخش‌های قبلی اشاره شد، متغیر هدف در این پژوهش مقدار دو دویی صفر و یک را اتخاذ می‌کند. منظور از صفر، در مسیر کف و منظور از ۱، در مسیر سقف می‌باشد. با فرض یک‌طرفه بودن بازار و عدم دسترسی به تعهد فروش یا فروش استقراضی، می‌توان یک استراتژی معاملاتی را مورد ارزیابی قرار داد. در صورتی که پیش‌بینی مدل‌ها از مقدار صفر به مقدار یک تبدیل شد، به این معنی است که پیش‌بینی مدل این است در مسیر یک سقف قرار گرفته‌ایم. بنابراین، در حالت می‌توان خرید انجام داد. سپس، وقتی بر عکس مقدار ۱ مجدد به مقدار ۰ تبدیل شد، منظور این است که در مسیر کف قرار گرفته‌ایم. بنابراین، می‌توان دارایی را مورد نظر را فروخت. سیستم معاملاتی در هر معامله ۱۰ درصد از سرمایه اولیه را درگیر می‌کند. سرمایه اولیه هزار دلار در نظر گرفته شده است. در هر کندل این سیستم فقط می‌تواند ۱ معامله باز داشته باشد و آن هم فقط خرید می‌باشد. سپس، عملکرد سیستم معاملاتی برای هر یک از مدل‌ها، با مقدار واقعی و استراتژی خرید و نگهداری مقایسه خواهد شد. در جدول (۳)، شاخص‌های عملکردی سیستم معاملاتی که مورد مقایسه قرار می‌گیرد، قابل مشاهده می‌باشد:

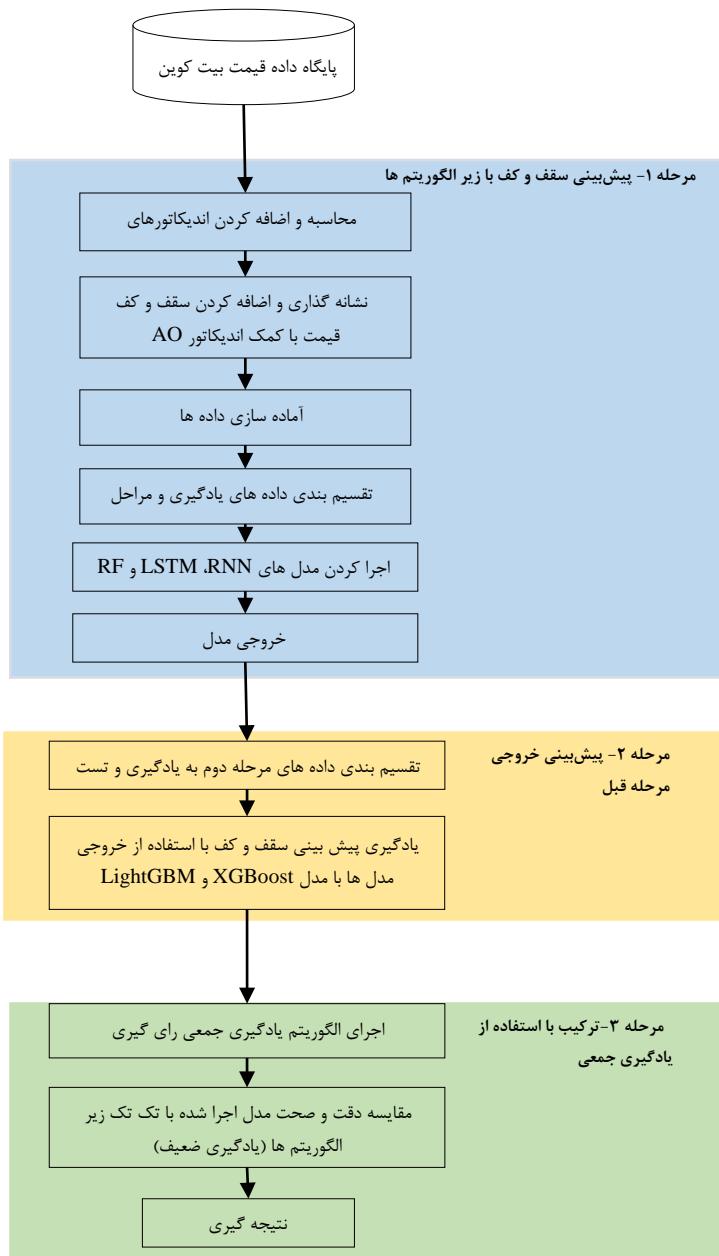
جدول ۳. شاخص‌های عملکردی سیستم معاملاتی

ردیف	نام شاخص عملکرد
۱	تعداد معامله
۲	تاریخ شروع
۳	تاریخ پایان
۴	کل سود یا ضرر
۵	بازدهی
۶	میانگین بازدهی هر معامله
۷	درصد موفقیت
۸	شاخص سود دهنده ^۱
۹	بیشترین افت سرمایه ^۲
۱۰	بیشترین سرمایه در لحظه

منبع: یافته‌های پژوهش

بازه زمانی داده‌های تست از ۲۰۲۲-۰۳-۱۱ تا ۲۰۲۲-۰۵-۳۰ می‌باشد. برای اجرا تست سیستم معاملاتی از فریم ورک پایتونی Freqtrade که مبتنی بر Docker می‌باشد، استفاده شده است.

1. Profit Factor
2. Max Draw Down (Max DD)

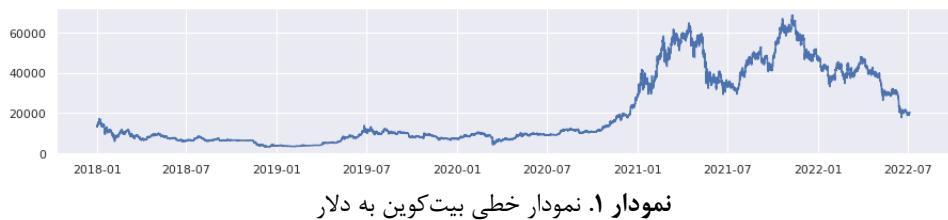


شکل ۱. مراحل اجرای پژوهش

تجزیه و تحلیل داده‌ها و آزمون فرضیه‌ها

مروجی بر داده‌ها

همانطور که در قسمت قبل گفته شد داده‌ها قیمت بیت‌کوین در بازه زمانی ۲۰۱۸ الی ۲۰۲۲ در تایم فریم ۱ ساعته بعد از فرآیند تمیز شدن برای کل مراحل مورد استفاده قرار گرفتند. نمودار (۱)، قیمت بیت‌کوین به صورت خطی از سال ۲۰۱۸ تا آخر ۶ ماهه اول سال به شکل زیر می‌باشد:



داده‌های قیمت بیت‌کوین در بازه زمانی اشاره شده دارای آمار توصیفی طبق جدول (۴)، می‌باشند:

جدول ۴. آمار توصیفی قیمت بسته شدن کنده‌های ۱ ساعته بیت‌کوین از ۲۰۱۸ تا آخر نیم سال اول ۲۰۲۲

ردیف	میانگین	مد	کوچکتری داده	بزرگترین داده	تعداد داده قیمت	مقدار شاخص
۱	۳۹,۴۸۴					
۲	۶۸,۶۳۹					
۳	۳۰,۱۳۹					
۴	۱۰,۱۴۲					
۵	۲۰,۳۸۴					
۶	۶,۳۹۹					
۷	۱۷,۸۷۶					
۸	۰,۹۷					
۹	-۰,۱۵۶					

منبع: یافته‌های پژوهش

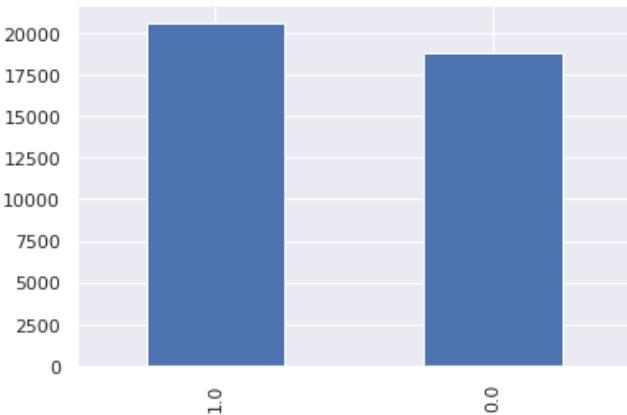
در نمودار (۲) برای داده آخر نمودار بیت‌کوین به همراه وضعیت سقف و کف را مشخص شده است که به عنوان داده هدف به مدل‌های یادگیری ماشین داده شده است:





نمودار ۲. قیمت بیت‌کوین به همراه وضعیت سقف و کف برای ۱۰۰ داده اخیر

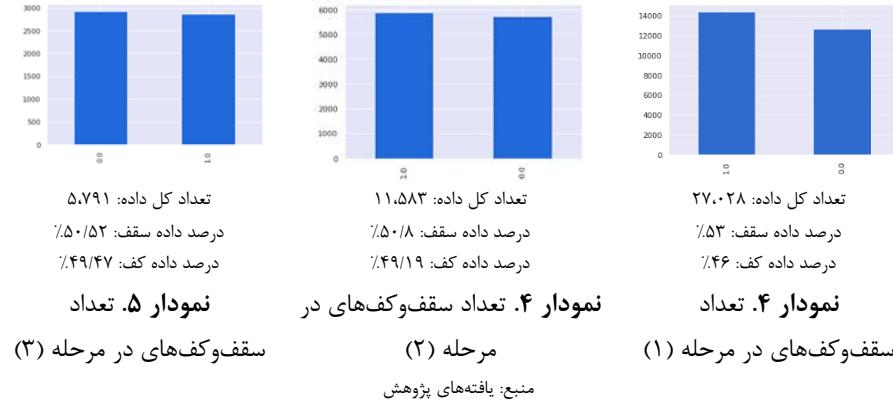
تعداد داده‌ها ۳۹,۴۸۴ می‌باشد. از کل این داده‌ها ۲۰,۶۶۳ (۵۲٪) داده وضعیت سقف و ۱۸,۸۲۱ (۴۷٪) داده وضعیت کف را نشان می‌دهد. این موضوع نشان از توزان نسبی میان تعداد داده سقف و کف را نشان می‌دهد.



نمودار ۳. تعداد وضعیت‌های سقف (۱) و کف (۰) در داده‌های قیمت بیت‌کوین برای کلیه مراحل

منبع: یافته‌های پژوهش

متوازن بودن داده‌های سقف و کف برای تمامی مراحل نیز می‌بایست به صورت مستقل بررسی شود. در نمودارهای ۴ تا ۶، تعداد سقف‌ها (۱) و کف‌ها (۰) به تفکیک مراحل پژوهش مشخص شده‌اند. این تعداد نشان‌دهنده توازن در متغیر هدف در تمامی مراحل می‌باشد.



ساختار و پارامترهای ورودی مدلها

مدلهای مرحله اول دارای ساختار و پارامترهای ورودی

جدول ۵. اطلاعات مربوط به ساختار مدل‌های LSTM و RNN در مرحله اول

ردیف	نام مدل	اطلاعات لایه	تعداد واحد	نسبت صفر کردن ورودی	تابع فعالیت
RNN	LSTM	لایه اول (لایه ورودی)	۶۴	-	hyperbolic tangent (tanh)
		لایه دوم	۶۴	-	hyperbolic tangent (tanh)
		لایه خروجی	۲ (باینری)	-	sigmoid
		لایه اول	۶۴	-	hyperbolic tangent (tanh)
	LSTM	Dropout	-	.۰/۲	-
		لایه دوم	۶۴	-	hyperbolic tangent (tanh)
		Dropout	-	.۰/۲	-
۲		لایه سوم (خروجی)	۲ (باینری)	-	softmax

منبع: یافته های پژوهش

لازم به ذکر است که پارامترهای ورودی با استفاده از جستجوی پنجره ای به دست آمده اند.

جدول ۶. شاخص‌های مربوط به توقف و اجرای یادگیری مدل‌های LSTM و RNN در مرحله اول

نام مدل	شاخص‌های اجرای یادگیری			شاخص توقف یادگیری		
	metrics	loss	optimizer	verbose	patience	Monitor
RNN	['accuracy']	binary_crossentropy	adam	۱	۳	'loss'
LSTM	['accuracy']	sparse_categorical_crossentropy	adam	۱	۳	'loss'

منبع: یافته های پژوهش

جدول ۷. ساختار مدل جنگل تصادفی در مرحله اول

Minimum number of samples required to be at a leaf node	تعداد کار همزمان	حداکثر عمق درخت	تعداد درخت	Criterion	نام مدل	ردیف
۲	using all processors	۲۰	۲۰	gini	Random Forest	۱

منبع: یافته‌های پژوهش

مدل LightGBM و XGBOOST

جدول ۸. ساختار مدل‌های LightGBM و XGBOOST

گاما	نسبت نمونه فرعی به آزمایشی	حداقل مجموع وزن نمونه مورد نیاز در یک بچه (برگ)	نسبت نمونه فرعی	حداکثر عمق درخت‌ها	نرخ یادگیری	تعداد درخت تقویت شده	نام مدل	ردیف
۰/۲۲	۰/۲۱	۴	۰/۲۵	۵	۰/۳	۲۱	XGBOOST	۱
-	۰/۵۸	۳	۰/۴	۱	۰/۱۹	۱۵	LightGBM	۲

منبع: یافته‌های پژوهش

لازم به ذکر است ما بقی پارامترها مقادیر پیش فرض در نظر گرفته شده است. مقادیر فوق نیز بر اساس تنظیم های پارامترهای^۱ به دست آمداند. برای مثال نرخ یادگیری اعدادی بین ۰/۰۱ تا ۰/۰۵ را با گامهای ۰/۰۱ طی کرده است تا به عدد بهینه ۰/۱۹ برای XGBoost و ۰/۳ برای LightGBM رسیده است. مباین پارامترها هم تنظیم شده‌اند. در این قسمت خروجی هر یک از مدل‌ها را با شاخص‌ها ارزیابی دقت، صحت، پوشش و F1 به صورت مستقل ارائه و تحلیل می‌شود. شاخص دقت^۲ حاصل تقسیم موارد درست پیش‌بینی شده به تمام موارد می‌باشد. شاخص صحت^۳ حاصل تقسیم مواردی مثبت درست تشخیص داده شده به موارد مثبتی است که درست یا غلط تشخیص داده شده است. در آخر شاخص پوشش^۴ عبارت است از موارد مثبت درست تشخیص داده شده تقسیم بر حاصل جمع داده‌های مثبت و منفی غلط تشخیص داده شده. امتیاز F1 که به صورت جدول (۹) محاسبه می‌شود، میانگینی از شاخص‌های صحت و پوشش می‌باشد:

جدول ۹. ماتریس اغتشاش^۵

پیش‌بینی توسط الگوریتم						
نحوه اغتشاش	بلی			خیر		
	بلی	True Positive (TP)		False Negative (FN)		
		False Positive (FP)		True Negative (TN)		

منبع: یافته‌های پژوهش

1. Tune Hyperparameters
2. Accuracy
3. Precision
4. Recall
5. Confusion Matrix

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad -1$$

$$\text{precision} = \frac{TP}{TP + FP} \quad -2$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad -3$$

$$f1\ score = \frac{2 \times (\text{precision} \times \text{Recall})}{\text{precision} + \text{Recall}} \quad -4$$

شاخص های فوق می توانند جهت مقایسه عملکرد پیش بینی مدل ها و مقایسه آن ها کمک کنند. در واقع هر کدام از آن ها با رویکرد مربوط به خود به دنبال سنجش صحت و دقت پیش بینی می باشند که هر چقدر به عدد ۱ نزدیک تر باشند، نشان از دقت بیشتر دارد. با توجه به اینکه شاخص f1 ترکیبی از شاخص های دقت و صحت می باشد، در این پژوهش جهت مقایسه عملکرد دو مدل بیشتر به این شاخص توجه می شود.

خروجی های مدل ها

خروجی مدل های یادگیری حافظه کوتاه و بلندمدت، شبکه عصبی بازگشتی، جنگل تصادفی و یادگیری جمعی در بازه تست (مرحله) سوم در جداول زیر ارائه می شود. لازم به ذکر است بازه زمانی تمامی خروجی ها با هم مشابه است تا بتوان عملکرد مدل ها را با یکدیگر مقایسه نمود. بنابراین، به میزان خروجی نهایی (داده تست) مدل یادگیری جمعی، خروجی های مدل های RNN، FR و LSTM مرتب شده تا بتوان نتایج را مقایسه نمود.

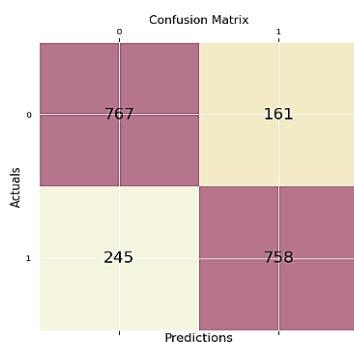
مدل RNN با پارامترهای ورودی مشخص شده در جدول (۳) و (۴) با متغیر هدف وضعیت سقف و کف و متغیرهای ویژگی معرفی شده نتایج زیر را داشته است:

جدول ۱۰. شاخص های ارزیابی خروجی مدل RNN

مدل شبکه عصبی بازگشتی - دقت٪/۷۹				
Support	F1	پوشش	صحت	هدف
۱۰۱۲	۰/۷۹	۰/۷۶	۰/۸۳	۰
۹۱۹	۰/۷۹	۰/۸۲	۰/۷۶	۱
۱۹۳۱	۰/۷۹	-	-	دقت
۱۹۳۱	۰/۷۹	۰/۷۹	۰/۷۹	میانگین ماکرو
۱۹۳۱	۰/۷۹	۰/۷۹	۰/۷۹	میانگین وزنی

منبع: یافته های پژوهش

همان طور که در جدول (۱۰) مشخص شده است، دقت مدل RNN در پیش‌بینی وضعیت سقف و کف ۷۹ درصد می‌باشد. صحت مدل در تشخیص کفها ۸۳ درصد و در سقفها ۷۶ درصد بوده است. این موضوع نشان‌دهنده عملکرد بهتر این مدل در تشخیص کفها نسبت به سقف‌های است. البته که بازار نزوی رمز ارزها در بازه تست شاید بتواند دلیل دیگر برای این تفاوت باشد. شاخص پوشش برای وضعیت‌های کف ۷۶ درصد و برای وضعیت‌های سقف ۸۲ درصد می‌باشد. شاخص F1 که یک شاخص متعادل برای مدل است نیز، عدد ۷۹ درصد را ثبت کرده است. به طور کلی، می‌توان گفت ۷۹ درصد از سقفها و کفها به درستی پیش‌بینی شده‌اند. در شکل (۲) ماتریس اغتشاش این مدل برای داده‌ای تست مشخص شده است:



شکل ۲. ماتریس اغتشاش RNN روی داده تست

منبع: یافته‌های پژوهش

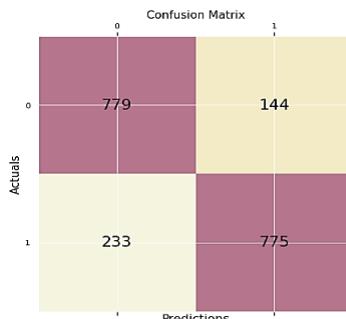
مدل LSTM بعدی است که در جدول (۹) شاخص‌های ارزیابی آن مورد بررسی قرار گرفته است. این مدل نیز بر اساس ساختار و هایپر پارامترهایی که در جدول (۳) و (۴) مشخص شده، اجرا شده است.

جدول ۱۱. شاخص‌های ارزیابی خروجی مدل LSTM

مدل یادگیری حافظه طولانی و کوتاه‌مدت - دقت: ۸۰٪				
Support	F1	پوشش	صحت	هدف
۱۰۱۲	۰/۸۱	۰/۷۷	۰/۸۴	-
۹۱۹	۰/۸۰	۰/۸۴	۰/۷۷	۱
۱۹۳۱	۰/۸۰	-	-	دقت
۱۹۳۱	۰/۸۰	۰/۸۱	۰/۸۱	میانگین ماکرو
۱۹۳۱	۰/۸۰	۰/۸۰	۰/۸۱	میانگین وزنی

منبع: یافته‌های پژوهش

همان طور که در جدول (۱۱) مشخص شده است، دقت مدل 80 درصد و نسبت به مدل RNN یک درصد بیشتر است. صحت مدل در پیش‌بینی وضعیت کف‌ها 84 و در وضعیت سقف‌ها 77 درصد می‌باشد. شبیه به RNN این مدل هم در تشخیص کف‌ها از سقف‌ها عملکرد بهتری از خود نشان داده است. شاخص پوشش برای وضعیت کف 77 درصد و برای وضعیت سقف 84 درصد می‌باشد. به طور کلی، شاخص F1 نیز نشان‌دهنده دقت 81 درصدی برای این مدل می‌باشد. در شکل (۳) ماتریس اغتشاش برای این مدل روی داده تست مشاهده می‌شود.



شکل ۳. ماتریس اغتشاش LSTM روی داده تست

منبع: یافته‌های پژوهش

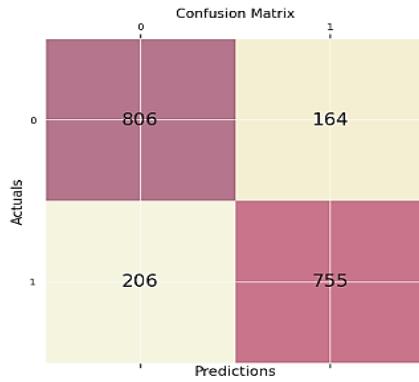
مدل جنگل تصادفی سومین مدلی است که بر اساس ساختار مدل و پارامترهای جدول (۵) روی داده‌ها اجرا شده است. در جدول (۱۲) شاخص‌های ارزیابی مدل مشاهده می‌شود:

جدول ۱۲. شاخص‌های ارزیابی خروجی مدل RF

مدل جنگل تصادفی - دقت: %۸۰,۸۳				
Support	F1	پوشش	صحت	هدف
۱۰۱۲	۰/۸۱	۰/۸۰	۰/۸۳	-
۹۱۹	۰/۸۰	۰/۸۲	۰/۷۹	۱
۱۹۳۱	۰/۸۱	-	-	دقت
۱۹۳۱	۰/۸۱	۰/۸۱	۰/۸۱	میانگین ماکرو
۱۹۳۱	۰/۸۱	۰/۸۱	۰/۸۱	میانگین وزنی

منبع: یافته‌های پژوهش

همان‌طور که در جدول (۱۲) مشخص شده است، دقت مدل جنگل تصادفی به‌طور کلی، $80/83$ درصد می‌باشد. این مدل نسبت به دو مدل LSTM و RNN دقت بیشتری دارد. صحت مدل در پیش‌بینی وضعیت کف 83 درصد و وضعیت سقف 79 درصد می‌باشد. شاخص پوشش برای وضعیت کف 80 درصد و برای سقف 82 درصد می‌باشد. شاخص F1 برای وضعیت کف و سقف به ترتیب 81 و 80 درصد می‌باشد. در شکل ۴ ماتریس اغتشاش برای RF ارائه شده است.



شکل ۴. ماتریس اغتشاش RF روی داده تست

منبع: یافته‌های پژوهش

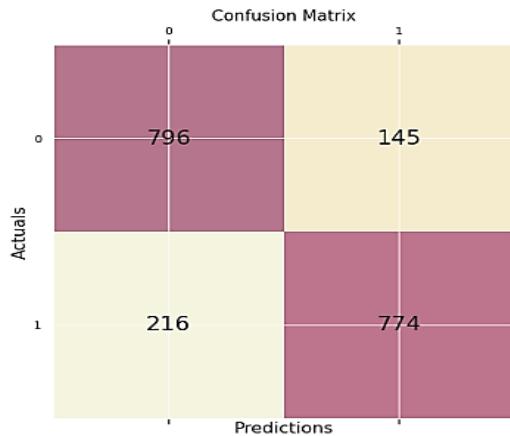
مدل یادگیری جمعی روی مدل‌های LightGBM و XGBoost اجرا شده است و نتایج شاخص‌های ارزیابی این ساختار در جدول (۱۳) ارائه شده است:

جدول ۱۳. شاخص‌های ارزیابی خروجی مدل یادگیری جمعی

مدل یادگیری جمعی روی خروجی LightGBM و XGBoost - دقت: ۸۱,۳۰٪				
Support	F1	پوشش	صحت	هدف
۱۰۱۲	۰/۸۲	۰/۷۹	۰/۸۵	۰
۹۱۹	۰/۸۱	۰/۸۴	۰/۷۸	۱
۱۹۳۱	۰/۸۱	-	-	دقت
۱۹۳۱	۰/۸۱	۰/۸۱	۰/۸۱	میانگین ماقرو
۱۹۳۱	۰/۸۱	۰/۸۱	۰/۸۲	میانگین وزنی

منبع: یافته‌های پژوهش

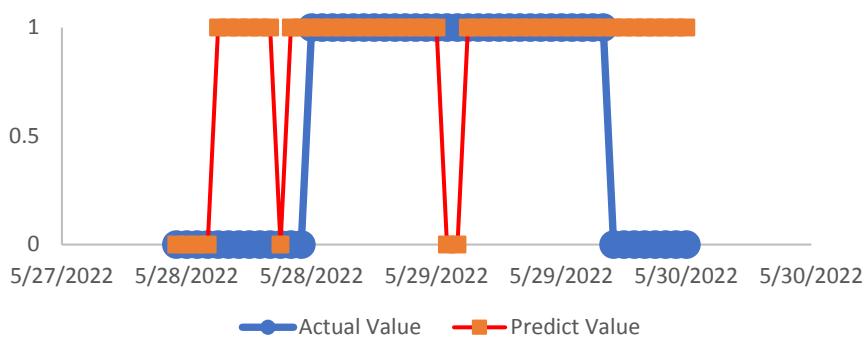
همانطور که در جدول (۱۳) مشخص شده است، دقت مدل $\frac{81}{100} \times 100 = 81\%$ درصد می‌باشد که نسبتاً به تمامی مدل‌ها (RNN, LSTM, RF) بیشتر است. صحت مدل در پیش‌بینی کف‌ها $\frac{85}{100} \times 100 = 85\%$ درصد و در سقف‌ها $\frac{78}{100} \times 100 = 78\%$ درصد می‌باشد. شاخص پوشش $\frac{79}{100} \times 100 = 79\%$ درصد برای کف‌ها و $\frac{84}{100} \times 100 = 84\%$ درصد سقف‌ها می‌باشد. شاخص F1 نیز $\frac{82}{100} \times 100 = 82\%$ درصد برای وضعیت کف و $\frac{81}{100} \times 100 = 81\%$ درصد برای وضعیت سقف می‌باشد. این اعداد نشان‌دهنده برتری مدل طراحی شده این پژوهش می‌باشد. ماتریس اغتشاش برای مدل یادگیری جمعی در شکل ۵ مشخص شده است.



شکل ۵. ماتریس اغتشاش Ensemble روی داده تست

منبع: یافته های پژوهش

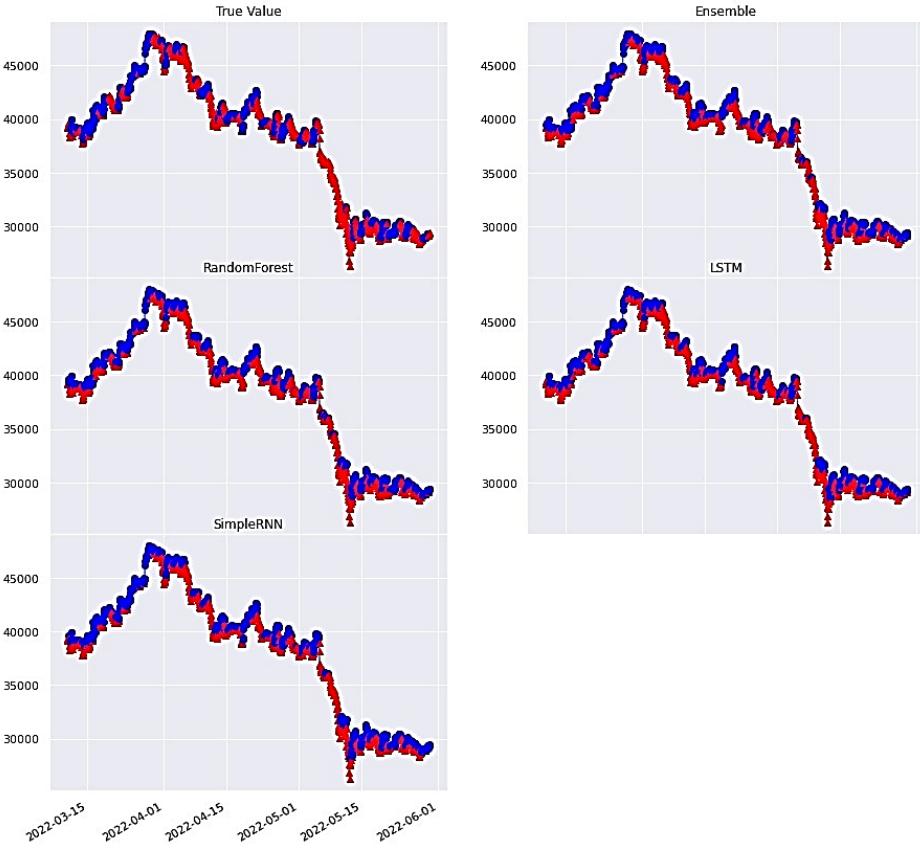
در نمودار (۷) مقادیر واقعی و ضعیت سقف و کف بیتکوین برای ۱۰۰ داده آخر در کنار مقادیر پیش‌بینی شده مدل یادگیری جمعی ارائه شده است. خط مشکی رنگ مقادیر پیش‌بینی شده و خط قرمز رنگ مقادیر واقعی می‌باشد. همانطوری که مشخص است بسیار از ضعیت‌ها (سقف یا کف) به صورت درست پیش‌بینی شده‌اند.



نمودار ۶. نمودار مقادیر واقعی سقف و کف در مقایسه با مقادیر پیش‌بینی شده توسط مدل یادگیری

جمعی
منبع: یافته های پژوهش

در نمودار (۷) می‌توان قدرت پیش‌بینی هر یک از الگوریتم‌ها در مقابل وضعيت‌های سقف و کف واقعی به صورت چشمی مورد مقایسه قرار داد.



نمودار ۷. مقایسه عملکرد پیش‌بینی مدل‌های یادگیری جمعی، جنگل تصادفی، حافظه کوتاه و بلند

مدت و شبکه عصبی بازگشتی در پیش‌بینی وضعیت سقف و کف واقعی

منبع: یافته‌های پژوهش

در نمودار (۸)، نمودار با عنوان True Value قیمت به بیت‌کوین به همراه نشانه گذاری وضعیت سقف و کف واقعی ارائه شده است. وضعیت سقف با رنگ آبی و وضعیت کف با رنگ قرمز مشخص شده است. مدل‌های پیش‌بینی سعی در پیش‌بینی این وضعیت‌ها (سقف‌ها و کف‌ها) دارند. تمامی مدل‌ها با عنوان‌های مدل‌های پیش‌بینی سعی در پیش‌بینی این وضعیت‌ها (سقف‌ها و کف‌ها) دارند. تمامی مدل‌ها با عنوان‌های SimpleRNN، LSTM، Random Forest، Ensemble، RandomForest، SimpleRNN و LSTM در نمودار (۸) با وضعیت‌های پیش‌بینی شده (سقف آبی و کف قرمز) مشخص شده است. این نمودار نشان‌دهنده عملکرد مناسبی تمامی مدل‌ها در پیش‌بینی سقف و کف می‌باشد.

در جدول (۱۴) شاخص‌های ارزیابی تمامی مدل‌ها به صورت تجمعی شده در کنار هم ارائه شده است.

جدول ۱۴. مقایسه شاخص ارزیابی مدل‌ها به صورت تجمیعی

F1-Score	پوشش	صحت	دقت	سقف / کف	نام مدل	ردیف
۰/۷۹	۰/۷۶	۰/۸۳	٪۷۹	۰	RNN	۱
۰/۷۹	۰/۸۲	۰/۷۶		۱		
۰/۸۱	۰/۷۷	۰/۸۴	٪۸۰	۰	LSTM	۲
۰/۸۰	۰/۸۴	۰/۷۷		۱		
۰/۸۱	۰/۸۰	۰/۸۳	٪۸۰، ۸۳	۰	RF	۳
۰/۸۰	۰/۸۲	۰/۷۹		۱		
۰/۸۲	۰/۷۹	۰/۸۵	٪۸۱، ۳۰	۰	Ensemble	۴
۰/۸۱	۰/۸۴	۰/۷۸		۱		

منبع: یافته‌های پژوهش

جدول (۱۴) نشان‌دهنده تقویت مدل‌ها در مدلی ۴ است که در این پژوهش ارائه شده است.

توانسته با شاخص F1 درصد برای وضعیت کف و ۸۱ درصد برای وضعیت سقف از تمامی Ensemble مدل‌های دیگر عملکرد بهتری را ارائه کند. بنابراین، به عنوان نتیجه‌ی می‌توان اعلام کرد که مدل Ensemble در این پژوهش عملکرد (دقت، صحت، پوشش و F1) بهتری نسبت به مدل‌های RF، RNN و LSTM در پیش‌بینی وضعیت سقف و کف بیت‌کوین دارد.

سیستم معاملاتی مبتنی بر مدل‌های پیش‌بینی و داده واقعی با توجه به اینکه مقادیر ۰ و ۱ را اتخاذ می‌کنند، بر اساس همین مقادیر معامله نیز خواهد کرد. به این معنی که وقتی عدد ۰ به ۱ تبدیل می‌شود سیگنال خرید و وقتی عدد ۱ به ۰ تبدیل می‌شود سیگنال فروش می‌باشد. مقدار سرمایه اولیه هزار دلار در نظر گرفته شده است. همچنین، برای هر معامله عدد ثابت ۱۰ درصد از سرمایه در نظر گرفته شده است. نتایج عملکرد هر یک از سیستم‌های معاملاتی در ادامه ارائه شده است.

در نمودار (۹) بازه تستی که در آن سیستم‌های معاملاتی تست شده‌اند مشخص شده

است:



نمودار ۸. مودار بیت‌کوین به تتر در بازه زمانی تست

منبع: یافته‌های پژوهش

همانطوری که در نمودار (۹) مشخص است بیت‌کوین پس از ۲۶ درصد رشد از قیمت ۳۸۱۵۰ دلار به ۴۸۲۵۳ دلار رسیده و پس از آن محدوده به محدوده ۳۷۵۰۰ دلار رسیده است. عملکرد هر یک از سیستم‌های معاملاتی در جدول زیر بر اساس شاخص‌های عملکردی را می‌توان مشاهده کرد:

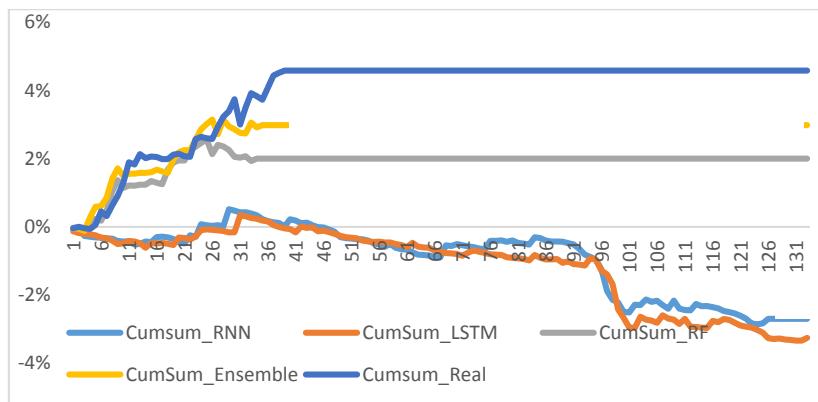
جدول ۱۵. مقایسه شاخص‌های عملکردی سیستم‌های معاملاتی مبتنی بر مدل‌های پیش‌بینی و داده‌های واقع

ردیف	نام سیستم معاملاتی	تعداد معامله	بازدهی (%)	افت سرمایه (%)	درصد موفقیت
۱	RNN مبتنی بر مدل	۱۲۶	-۰/۲۷۰	۰/۳۷۲۶	٪۲۳
۲	LSTM مبتنی بر مدل	۱۲۲	-۰/۳۲۵	۰/۳۶۶	٪۲۱/۸
۳	RF مبتنی بر مدل	۳۴	٪۰/۲	۰/۰۶۲	٪۵۸
۴	مبتنی بر مدل یادگیری جمعی پیشنهاد شده	۳۵	٪۰/۹۸	۰/۰۴۲	٪۶۰
۵	مبتنی بر داده‌های واقعی سقف و کف	۳۹	٪۰/۵۹	۰/۰۷۱	٪۵۹

منبع: یافته‌های پژوهش

همان‌طور که در جدول ۱۵ مشخص شده است، سیستم معاملاتی مبتنی بر مدل یادگیری جمعی پیشنهاد شده در این پژوهش، توانسته است بازدهی بیشتر از سایر مدل‌ها و نزدیک به مدل مبتنی بر داده‌های واقعی سقف و کف را ایجاد کند. این سیستم معاملاتی توانسته است بازدهی ۲/۹۸ درصد را با شاخص افت سرمایه ۴۲٪ ایجاد کند. شاخص افت سرمایه این سیستم از استراتژی مبتنی بر داده‌های

واقعی نیز کمتر است که نشان می‌دهد میزان سرمایه و ریسک هر معامله را برای استراتژی یادگیری جمعی پیشنهادی افزایش داد. در نمودار زیر بازدهی تجمعی هر یک از سیستم‌ها را می‌توان با هم مقایسه نمود:

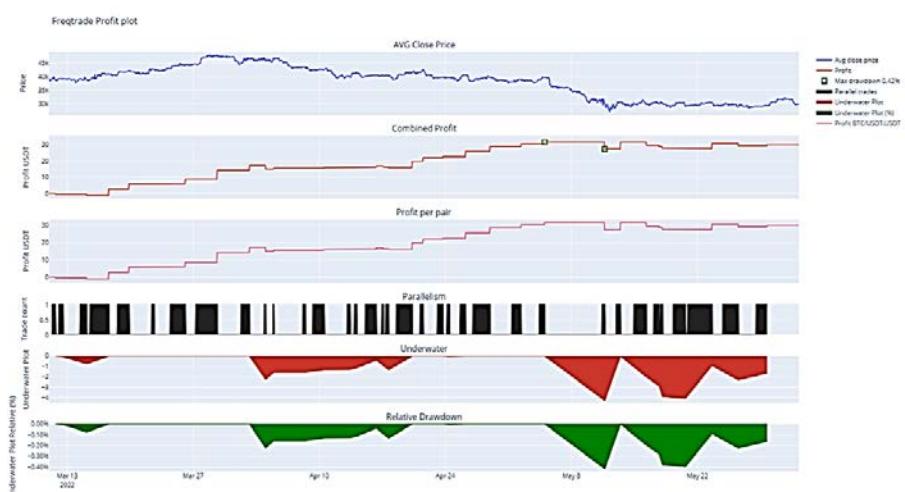


نمودار ۹. نمودار مقایسه بازدهی تجمعی سیستم‌های معاملاتی مبتنی بر RNN، LSTM، RF و Cumsum.

یادگیری جمعی پیشنهادی به همراه داده واقعی سقف و کف

منبع: یافته‌های پژوهش

در نمودار ۱۱ عملکرد سیستم معاملاتی مبتنی بر یادگیری جمعی مشخص شده است:



نمودار ۱۰. عملکرد سیستم معاملاتی مبتنی بر یادگیری جمعی پیشنهادی

منبع: یافته‌های پژوهش

بحث و نتیجه‌گیری

در بخش قبل، خروجی و شاخص‌های ارزیابی به صورت مستقل ارائه و بررسی شد. این بخش به دنبال پاسخ شفاف به سوالات پژوهش می‌باشد. با توجه به نقاط قوت و قابل بهبود هر یک از مدل‌های یادگیری ماشین در پیش‌بینی می‌توان گفت در صورتی که مدلی به عنوان مدل ترکیبی خروجی‌های مدل‌ها را تجمیع و تصمیم‌گیری کند می‌تواند عملکرد بهتری در پیش‌بینی داشته باشد. در این پژوهش، نتایج مدل‌های شبکه عصبی بازگشتی، یادگیری حافظه کوتاه و بلندمدت و جنگل تصادفی به عنوان ورودی به یک مازول یادگیری جمعی ارائه شد. مازول یادگیری جمعی با استفاده از مدل‌های یادگیری ماشین XGBoost و LightGBM خروجی‌های مدل‌های اشاره شده را با الگوریتم یادگیری جمعی مبتنی بر رای‌گیری ترکیب می‌کند. فرضیه این پژوهش تقویت دقت پیش‌بینی مدل ارائه شده نسبت به هر یک از زیر الگوریتم‌ها می‌باشد. با با توجه به خروجی‌های ارائه شده در بخش اجرای مدل‌ها، این فرضیه مورد پذیرش قرار گرفت. بر اساس جدول (۱۴) مازول یادگیری جمعی توانسته است بر اساس شاخص‌های دقت، صحت، پوشش و F1 عملکرد مناسب‌تری نسبت به هر یک از زیر الگوریتم‌ها در زمان مشابه نشان دهد. بنابراین، سوالات این پژوهش را می‌توان به صورت زیر پاسخ داد:

- سیستم معاملاتی هوشمند و الگوریتمی مبتنی بر یادگیری جمعی پیشنهاد شده این پژوهش توانست نزدیک تری بازدهی را به بازدهی سیستم معاملاتی مبتنی بر داده‌ها واقعی سقف و کف را ایجاد کند. همچنین ریسک (شاخص افت سرمایه) آن نسبت به سیستم معاملاتی مبتنی بر داده‌های واقعی کمتر و از مابقی سیستم‌ها بهتر بوده است. (جدول ۱۵)
- میزان دقت و صحت پیش‌بینی مدل یادگیری جمعی در پیش‌بینی وضعیت سقف و کف قیمت بیت‌کوین به ترتیب $81/31\%$ و 82% می‌باشد. (جدول ۱۴)
- میزان دقت و صحت مدل یادگیری جمعی بر اساس شاخص‌های دقت، صحت، پوشش و F1 نسبت به تمامی زیر الگوریتم‌ها بیشتر است (جدول ۱۴).

در پژوهش حاضر دقت پیش‌بینی توسط این مدل به $81/31$ درصد افزایش یافته است این در حالی است که در پژوهش‌ها دقت این مدل 56 درصد (بشیری و پاریاب، ۱۳۹۹) و 69 درصد (مشاری و همکاران، ۱۳۹۸) بوده است. همچنین، نتیجه این پژوهش با پژوهش باسک^۱ و همکاران^۲ (۲۰۱۹) مطابقت دارد. زیرا در این پژوهش نیز، مدل RF با مدل‌های SVM، ANN، XGBoost و رگرسیون لاجستیک مورد مقایسه قرار گرفته و نشان داده شده است مدل RF از دقت بیشتری برخوردار است. از طرفی بهبود بازدهی و ریسک سیستم معاملاتی در بازه 1 ساعته با در نظر گرفتن نگاه گستته با پژوهش جاکارت^۲ و همکاران مطابقت دارد. اما مدل پیشنهادی این پژوهش جنبه نوآوری این پژوهش هست و کاملاً با رویکرد این پژوهش متفاوت است. اما از این نظر که سبب بهبود استراتژی در تایم فریم 1 ساعته شده است تطابق‌هایی وجود دارد.

1. Basak
2. Jaquart

پیشنهادهای این پژوهش عبارتند از:

- استفاده از داده چند دارایی به طول همزمان و یکپارچه‌سازی: به این معنی که به جای اینکه مدل صرفاً روی داده‌های بیت‌کوین آموزش دیده و پیش‌بینی نماید می‌تواند به طور همزمان چند دارایی در یک بازار (تریوم، لایت کوین و غیره) یا حتی چند بازار (طلاء، ارز، شاخص بورس آمریکا و غیره) را آموزش و سپس، پیش‌بینی نماید.
- استفاده از اندیکاتورهای دیگر برای تشخیص سقف و کف مانند ZigZag و مقایسه آن با نتیجه مدل فعلی که از اندیکاتور AO استفاده کرده است.
- اضافه کردن متغیرهای بنیادی^۱ و ادراکی^۲ بازار به عنوان متغیرهای ویژگی با هدف افزایش دقت پیش‌بینی می‌تواند کمک بسزایی کند. همچنین مقایسه مدل‌ها و تاثیر اضافه کردن این داده‌ها می‌تواند به نتایج دیگری پژوهش کمک کند.
- مقایسه عملکرد مدل در تایم فریم‌های متفاوت محدودیت‌های پژوهش عبارتند از:
 - شرط توقف همراه با تایم فریم پایین‌تر به دلیل پیچیدگی و همچنین، نیاز به محاسبات بالا نیاز به سخت افزار با مشخصات نسبتاً بالایی دارد.
 - چند دارایی به طور همزمان با توجه به پایگاه داده حجمی و فرخوانی و پردازش آن نیاز به سخت افزار با مشخصات نسبتاً بالایی دارد.
 - تفاوت جزئی قیمت بیت‌کوین در صرافی‌های متفاوت می‌تواند روی عملکرد و خروجی مدل تاثیرگذار باشد.

ملاحظات اخلاقی

حامی مالی: مقاله حامی مالی ندارد.

مشارکت نویسندها: تمام نویسندها در آماده‌سازی مقاله مشارکت داشته‌اند.

تعارض منافع: بنابر اظهار نویسندها در این مقاله هیچ‌گونه تعارض منافع وجود ندارد.

تعهد کپیرایت: طبق تعهد نویسندها حق کپیرایت رعایت شده‌است.

References

- Aggarwal, D; Chandrasekaran, S; & Annamalai, B. (2020). A complete empirical ensemble mode decomposition and support vector machine-based approach to predict Bitcoin prices. *Journal of Behavioral and Experimental Finance*, 27, Article 100335. <https://doi.org/10.1016/j.jbef.2020.100335>
- Aghakhani, K; & Karimi, A. (2014). Investigating methods for predicting stock prices in the stock market and introducing an optimized method. In *National Conference on New Achievements in Engineering and Basic Sciences* (pp. 1-7). Ardabil. (In Persian)
- Ampomah, E; Qin, Z; & Nyame, G. (2020). Evaluation of tree-based ensemble machine learning models in predicting stock price direction of movement. *Information*, 11(6), 332. <https://doi.org/10.3390/info11060332>
- Basak, S; Kar, S; Saha, S; Khadem, L; & Dey, S. (2018). Predicting the direction of stock market prices using tree-based classifiers. The North American *Journal of Economics and Finance*, 47, Article 102-117. <https://doi.org/10.1016/j.najef.2018.06.013>
- Faghihi Nezhad, M; & Minaei Bidgoli, B. (2021). Development of an ensemble learning-based intelligent model for stock market forecasting. *Scientia Iranica*, 28(1), 395-411. <https://doi.org/10.24200/sci.2019.50353.1654>
- Gupta, A; & Nain, H. (2020). Bitcoin price prediction using time series analysis and machine learning techniques. In A. Das, K. Deep, A. Tiwari, R. Kumar, & R. Bansal (Eds.), *Intelligent Communication, Control and Devices* (pp. 533-542). Springer. https://doi.org/10.1007/978-981-15-7106-0_54
- Jiang, M; Liu, J; Zhang, L; & Liu, C. (2020). An improved stacking framework for stock index prediction by leveraging tree-based ensemble models and deep learning algorithms. *Physica A: Statistical Mechanics and its Applications*, 541, Article 123390.
- Li, Y; & Pan, Y. (2022). A novel ensemble deep learning model for stock prediction based on stock prices and news. *International Journal of Data Science and Analytics*, 13(1), 139-149. <https://doi.org/10.1007/s41060-021-00279-9>
- Mallqui, D. C. A; & Fernandes, R. A. S. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques. *Applied Soft Computing*, 75, 596-606. <https://doi.org/10.1016/j.asoc.2018.11.038>
- Mohammadi Almoti, M; Haddadi, M. R; & Nadimi, Y. (2018). Modeling and evaluating different prediction models: Short-term memory, long-term memory, Markov switching, and hyperbolic tangent in predicting crude oil price fluctuations of OPEC. *Financial Engineering and Securities Management Quarterly*, 9(34), 249-272. (In Persian)
- Moshari, M; et al. (2019). Designing a combined intelligent model for predicting golden points of stock prices. *Investment Knowledge Quarterly*, 8(29), 45-65. (In Persian)
- Mousavi, S. O. (2019). Algorithmic Trading Technology: New Solutions in the Iranian Capital Market. Challenge Publications. (In Persian)
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. *Decentralized Business Review*, 21260.

- Nti, I. K; Adekoya, A. F; & Weyori, B. A. (2019). Random forest-based feature selection of macroeconomic variables for stock market prediction. *American Journal of Applied Sciences*, 16(7), 200-212. <https://doi.org/10.3844/ajassp.2019.200.212>
- Nti, I. K; Adekoya, A. F; & Weyori, B. A. (2020). A comprehensive evaluation of ensemble learning for stock-market prediction. *Journal of Big Data*, 7(1), Article 20. <https://doi.org/10.1186/s40537-020-00299-5>
- Shirzoor Aliabadi, Z; & Ramazanzadeh, H. (2020). Bitcoin and its future prediction. Sixth International Conference on Industrial Engineering and Systems, Mashhad. (In Persian)
- Tehrani, E; & Esmaili, A. (2012). Investigating the effect of using important technical analysis indicators on short-term investors' returns in the Tehran Stock Exchange. *Financial Knowledge-Based Securities Analysis*, 5(13), 21-33. (In Persian)
- Yun, K. K; Yoon, S. W; & Won, D. (2021). Prediction of stock price direction using a hybrid GA-XGBoost algorithm with a three-stage feature engineering process. *Expert Systems with Applications*, 186, Article 115716. <https://doi.org/10.1016/j.eswa.2021.115716>
- Yang, Y; Wu, Y; Wang, P; & Jiali, X. (2021). Stock price prediction based on XGBoost and LightGBM. *E3S Web of Conferences*, 275, Article 01040. <https://doi.org/10.1051/e3sconf/202127501040>

COPYRIGHTS



This license allows others to download the works and share them with others as long as they credit them, but they can't change them in any way or use them commercially.