

کاهش درصد خطای پیش‌بینی سری‌های زمانی قیمت رمزارزها با استفاده از دوسویه‌سازی شبکه‌های عصبی یادگیری عمیق

فتانه کاظم‌زاده، مسعود هوشمند کفاشیان و منیره هوشمند

زمانی، به یکی از ابزارهای اصلی در پیش‌بینی‌های مهندسی تبدیل شده‌اند. این شبکه‌ها قادر به شناسایی وابستگی‌های طولانی‌مدت و الگوهای پنهان در داده‌ها هستند، که این ویژگی‌ها برای پیش‌بینی دقیق و به موقع ضروری است [۳]. در زمینه مالی، پیش‌بینی قیمت رمزارزها به دلیل نوسانات بالا و پیچیدگی‌های بازار آن، به یک چالش بزرگ تبدیل شده است. به همین دلیل، انتخاب سری‌های زمانی مالی به عنوان یک مطالعه موردی، می‌تواند نمونه مناسبی برای نمایش کاربردهای وسیع این روش‌ها در پیش‌بینی سری‌های زمانی باشد [۴]. پژوهش‌های پیشین نشان داده‌اند که استفاده از شبکه‌های عصبی دوطرفه می‌تواند دقت پیش‌بینی‌ها را به طور قابل توجهی افزایش دهد. این شبکه‌ها با استفاده از اطلاعات گذشته و آینده به طور همزمان، قادر به مدل‌سازی بهتر دینامیک‌های پیچیده در سری‌های زمانی هستند [۵] تا [۷].

هدف اصلی این پژوهش، کاهش درصد خطای پیش‌بینی قیمت رمزارزها با استفاده از دوسویه‌سازی شبکه‌های عصبی LSTM و GRU است. پیش‌بینی قیمت رمزارزها به دلیل نوسانات سریع و تأثیرپذیری از عوامل خارجی (مانند اخبار) با خطای بالینی همراه است. پژوهش‌های پیشین نشان داده‌اند که مدل‌های یکسویه LSTM در شناسایی الگوهای بلندمدت ضعف دارند. این پژوهش به دنبال پر کردن این شکاف با استفاده از دوسویه‌سازی و بهینه‌سازی هایپرپارامترها برای کاهش خطا در پیش‌بینی روزانه قیمت است. به طور کلی، پژوهش‌های پیشین نشان داده‌اند که استفاده از شبکه‌های عصبی مانند LSTM، GRU و Bi-LSTM^۳ به ویژه زمانی که به صورت ترکیبی استفاده شوند، می‌تواند به طور قابل توجهی خطای پیش‌بینی را کاهش دهند. با توجه به نتایج مثبت به دست آمده در تحقیقات پیشین، انتظار می‌رود که استفاده از این روش‌ها بتواند دقت پیش‌بینی قیمت رمزارزها را به طور قابل توجهی بهبود بخشد [۸] و [۹]. در این پژوهش، از داده‌های تاریخی قیمت رمزارزها به عنوان داده‌های ورودی استفاده خواهد شد و عملکرد شبکه‌های عصبی دوسویه LSTM و GRU با یکسویه در حالتی مقایسه خواهد شد که هایپرپارامترها بر خلاف پژوهش‌های پیشین ثابت نبوده و با استفاده از انتخاب بهترین روش بهینه‌سازی برای هر مدل، در حالت بهینه تنظیم شده‌اند تا از مزایای دوسویه‌سازی بیشترین بهره را برده شود. به منظور یافتن ترکیب بهینه هایپرپارامترها برای مدل‌های LSTM و GRU، از سه روش بهینه‌سازی جستجوی شبکه‌ای^۴، جستجوی اتفاقی CV^۵ و بیزین^۶ استفاده می‌شود. این روش‌ها به دلیل توانایی آن‌ها در جستجوی فضای هایپرپارامترها و بهبود

چکیده: پیش‌بینی سری‌های زمانی در حوزه‌های مهندسی، مخابرات و امور مالی از اهمیت بالایی برخوردار است. سری‌های زمانی مالی، که اغلب چند متغیره هستند، نیاز به الگوریتم‌های دقیق و بهینه دارند. در پژوهش‌های سال‌های اخیر، شبکه‌های عصبی عمیق در بهبود دقت پیش‌بینی سری‌های زمانی مالی نتایج موفق‌تری نشان داده‌اند. این پژوهش به بررسی استفاده از شبکه‌های LSTM و GRU در پیش‌بینی قیمت رمزارزها پرداخته و رویکرد دوسویه‌سازی این شبکه‌ها را با تأکید به انتخاب بهینه هایپرپارامترها به منظور کاهش خطای پیش‌بینی و افزایش دقت با استفاده از روش‌های جستجوی شبکه‌ای، جستجوی اتفاقی CV و بیزین مورد مطالعه قرار می‌دهد. نتایج شبیه‌سازی نشان می‌دهند که استفاده از شبکه‌های دو سویه LSTM و شبکه دوسویه BiGRU کاهش درصد خطا را برای رمزارز BTC تا ۳٫۲۲٪، برای ETH تا ۳٫۹۴٪، و برای LTC تا ۳٫۹۹٪ به همراه داشته است.

کلیدواژه: پیش‌بینی سری‌های زمانی، یادگیری عمیق، شبکه عصبی دوطرفه، پیش‌بینی قیمت رمزارزها، خطای پیش‌بینی شبکه عصبی، درصد خطای پیش‌بینی قیمت.

۱- مقدمه

پیش‌بینی سری‌های زمانی در علوم مهندسی اهمیت بسیاری دارد، زیرا این سری‌ها می‌توانند به ما در درک و پیش‌بینی رفتار سیستم‌های پیچیده کمک کنند. به عنوان مثال، در حوزه مخابرات، پیش‌بینی سری‌های زمانی می‌تواند به بهبود کیفیت خدمات، مدیریت منابع و افزایش کارایی سیستم‌ها منجر شود. همچنین، با پیش‌بینی دقیق بار شبکه، می‌توان ترافیک را بهتر مدیریت کرد و از ازدحام جلوگیری نمود [۱]. در این راستا، استفاده از روش‌های پیشرفته یادگیری عمیق مانند شبکه‌های عصبی حافظه طولانی کوتاه‌مدت^۱ (LSTM) و واحدهای بازگشتی دروازه‌ای^۲ (GRU) نقش مهمی در بهبود دقت پیش‌بینی‌ها ایفا می‌کند [۲]. شبکه‌های عصبی یادگیری عمیق به دلیل توانایی‌های بالای خود در مدل‌سازی و پیش‌بینی الگوهای پیچیده و غیرخطی در داده‌های سری

این مقاله در تاریخ ۲۶ آبان ماه ۱۴۰۳ دریافت و در تاریخ ۶ فروردین ماه ۱۴۰۴ بازنگری شد.

فتانه کاظم‌زاده، گروه مهندسی برق، دانشگاه بین‌المللی امام رضا (ع)، مشهد، ایران، (email: kazemzadeh@imamreza.ac.ir).

مسعود هوشمند کفاشیان، شرکت مخابرات ایران، مشهد، ایران، (email: m.houshmand@gmail.com).

منیره هوشمند (نویسنده مسئول)، گروه مهندسی برق، دانشگاه بین‌المللی امام رضا (ع)، مشهد، ایران، (email: m.hooshmand@imamreza.ac.ir).

1. Long Short-Term Memory

2. Gated Recurrent Unit

3. Bidirectional Long Short-Term Memory

4. Grid Search

5. RandomizedSearchCV

6. Bayesian

این یافته‌ها به توانایی شبکه‌های دوسویه در مدل‌سازی الگوهای پیچیده زمانی تأکید می‌کند.

علاوه بر این، در پژوهش [۶] نویسندگان، با استفاده از تکنیک‌های یادگیری عمیق برای پیش‌بینی قیمت بیت‌کوین نشان دادند که شبکه‌های LSTM با خطای برابر با ۰/۰۹ و GRU با خطای برابر با ۰/۰۸ عملکرد بهتری دارند. این مطالعه تأکید می‌کند که تکنیک‌های یادگیری عمیق می‌توانند دقت پیش‌بینی قیمت رمزارزها را بهبود بخشند. در مطالعه‌ای دیگر، مدلی جدید ترکیبی از LSTM، GRU و Bi-LSTM برای پیش‌بینی قیمت رمزارزها پیشنهاد شد. نتایج نشان داد که این مدل ترکیبی توانسته است خطا را تا ۲۰٪ کاهش دهد و به ۰/۰۵ برساند [۱۳]. این تحقیق نشان می‌دهد که مدل‌های ترکیبی می‌توانند در بهبود دقت پیش‌بینی مؤثر باشند. در [۱۴]، رویکردی مبتنی بر انتخاب ویژگی و وزن‌دهی با استفاده از مدل LSTM ارائه شده است که با اصلاح سوگیری مدل و حفظ روندهای قیمتی، توانسته است عملکرد پیش‌بینی را بهبود بخشد. این روش به‌ویژه در شرایط نوسانات شدید بازار، نتایج قابل قبولی ارائه داده است. در همین راستا، در [۱۵] با ترکیب دو مدل LSTM و GRU، مدلی هیبریدی برای پیش‌بینی قیمت بیت‌کوین طراحی کرده‌اند که توانسته است مزایای هر دو ساختار را در یادگیری وابستگی‌های زمانی و کاهش پیچیدگی محاسباتی تلفیق کند. این مدل در مقایسه با مدل‌های منفرد، دقت بالاتری در پیش‌بینی قیمت‌ها نشان داده است. در [۱۶] با تمرکز بر بیت‌کوین و اتریوم، از مدل‌های LSTM و GRU برای تحلیل سری‌های زمانی قیمتی استفاده کرده‌اند. آن‌ها نشان داده‌اند که مدل‌های بازگشتی در مواجهه با داده‌های نوسانی عملکرد مناسبی دارند و می‌توانند روندهای پنهان بازار را شناسایی کنند. در مطالعه‌ای دیگر، از شبکه‌های عصبی کانولوشنی^۴ (CNN) با جهت‌گیری دوگانه بهره گرفته‌اند تا ویژگی‌های مکانی-زمانی داده‌های قیمتی را استخراج کنند. این مدل توانسته است الگوهای پیچیده بازار را با دقت بیشتری شناسایی کرده و در پیش‌بینی قیمت رمزارزها مؤثر واقع شود [۱۷]. در نهایت، در [۱۸] با تلفیق روش تجزیه مد تجزیه^۵ (EMD) و شبکه‌های LSTM، مدلی ارائه داده‌اند که ابتدا داده‌های قیمتی را به مؤلفه‌های فرکانسی تجزیه کرده و سپس با استفاده از LSTM روندهای پنهان را پیش‌بینی می‌کند. این رویکرد به‌ویژه در کاهش نویز داده‌ها و افزایش دقت پیش‌بینی مؤثر بوده است.

۳- روش پیشنهادی

در این بخش، به معرفی و تشریح روش پیشنهادی برای کاهش خطای پیش‌بینی قیمت رمزارزها خواهیم پرداخت. این روش شامل تحلیل و مدل‌سازی با استفاده از شبکه‌های عصبی دوسویه و مقایسه عملکرد آنها با مدل‌های یک‌سویه است. همچنین بر روی فرآیند جمع‌آوری داده‌ها، پیش‌پردازش، مدل‌سازی، بهینه‌سازی هاپارامترها و ارزیابی نتایج تمرکز خواهیم کرد.

۳-۱- دلایل انتخاب LSTM و GRU و رویکرد دوسویه‌سازی برای کاهش خطا

در این پژوهش، استفاده از شبکه‌های عصبی LSTM و GRU به‌ویژه در نسخه‌های دوسویه آن‌ها (BiLSTM و BiGRU) به‌عنوان روش

عملکرد مدل‌های یادگیری عمیق، به طور گسترده در تحقیقات مختلف مورد استفاده قرار گرفته‌اند [۱۰] و [۱۱]. نتایج به‌دست‌آمده از آزمون‌های انجام‌شده نشان می‌شود که برای مدل LSTM، روش جستجوی شبکه‌ای و برای مدل GRU، روش جستجوی اتفاقی CV بهترین عملکرد (کمترین درصد خطا) را در پیش‌بینی قیمت بیت‌کوین ارائه دادند. در نهایت، با توجه به اهمیت و کاربرد گسترده پیش‌بینی سری‌های زمانی در علوم مهندسی و مالی، نتایج این تحقیق می‌تواند به توسعه ابزارهای پیش‌بینی دقیق‌تر کمک کرده و از ضررهای مالی احتمالی جلوگیری کند. این پژوهش همچنین می‌تواند به تحقیقات آینده در زمینه پیش‌بینی سری‌های زمانی مالی و اقتصادی کمک کند و بهبود روش‌های موجود را تسهیل نماید [۳] و [۱۲].

ادامه مقاله بدین صورت سازمان‌دهی شده است. در بخش ۲، کارهای پیشین مرتبط مورد بررسی قرار می‌گیرد. در بخش ۳، روش پیشنهادی به تفصیل بیان می‌شود. در بخش ۴، نتایج تحلیل گردیده و بخش ۵ مقاله جمع‌بندی می‌شود.

۲- مرور ادبیات

در سال‌های اخیر، استفاده از روش‌های یادگیری عمیق برای پیش‌بینی قیمت رمزارزها مورد توجه زیادی قرار گرفته است. از جمله این روش‌ها، شبکه‌های عصبی بازگشتی مانند LSTM و GRU هستند که به دلیل توانایی بالای آن‌ها در مدل‌سازی داده‌های زمانی، به طور گسترده‌ای مورد استفاده قرار گرفته‌اند. این بخش به مرور پژوهش‌های پیشین در این زمینه و بررسی پیشرفت‌های اخیر در کاهش خطای پیش‌بینی سری‌های زمانی می‌پردازد.

تحقیقات متعدد نشان داده‌اند که LSTM و GRU می‌توانند به طور مؤثری برای پیش‌بینی قیمت رمزارزها استفاده شوند. به عنوان مثال، پژوهش [۲] نشان می‌دهد که استفاده از مدل‌های مبتنی بر LSTM در پیش‌بینی قیمت بیت‌کوین باعث کاهش خطا نسبت به مدل‌های سنتی شده است. نویسندگان این تحقیق با استفاده از شبکه‌های LSTM ترکیبی، موفق به کاهش خطای میانگین مطلق^۱ (MAE)، به مقدار ۰/۰۵ شدند.

در مطالعه‌ای دیگر، عملکرد LSTM و GRU را در پیش‌بینی داده‌های وبسایت^۲ Yelp مقایسه کردند. نتایج نشان داد که GRU نسبت به LSTM دقت بیشتری دارد و توانسته است خطا را به ۰/۱۸ کاهش دهد، در حالی که برای LSTM این مقدار ۰/۲۲ است [۳].

در زمینه پیش‌بینی قیمت رمزارزها، نویسندگان پژوهش [۱۲] به بررسی توانایی LSTM، GRU و Bi-LSTM پرداختند. نتایج آنها نشان داد که Bi-LSTM با خطای برابر با ۰/۰۳، کمترین درصد خطای پیش‌بینی را ارائه داده است و نسبت به LSTM و GRU عملکرد بهتری داشته است. این مطالعه به اهمیت شبکه‌های دوطرفه در بهبود دقت پیش‌بینی اشاره می‌کند.

در پژوهش دیگری، محققان از شبکه‌های LSTM و GRU دوجهته و انباشته^۳، برای پیش‌بینی بازار سهام استفاده کردند. آنها نشان دادند که مدل‌های LSTM دوجهته توانسته است خطای پیش‌بینی را تا ۱۵٪ کاهش دهند و خطای پیش‌بینی به مقدار ۰/۰۷ کاهش یافته است [۵].

1. Mean Absolute Error
2. <https://www.yelp.com>
3. Stacked

4. Convolutional Neural Network

5. Empirical Mode Decomposition

۳-۲- تشریح روش پیشنهادی

در این بخش روش پیشنهادی به تفصیل بیان می‌گردد.

۳-۲-۱- توصیف داده‌ها

- منابع داده‌ها

مجموعه داده‌ها، توسط برنامه‌ی نوشته شده به زبان پایتون، به صورت آنلاین از یاهو فایننس^۱ دریافت شد (بازهی زمانی اول ژانویه ۲۰۱۶ تا بیستم ماه مه ۲۰۲۴ و قیمت بر اساس دلار آمریکا^۲ تعریف شد). شکل ۱، نمونه داده‌های برچسب‌داری از مجموعه داده سه رمارز مورد استفاده در این مطالعه را نشان می‌دهد و جدول ۱ نیز مشخصات پارامترهای مجموعه داده‌ی دریافت‌شده را ارائه می‌کند.

- انتخاب ویژگی‌ها

در این پژوهش، دو ویژگی اصلی انتخاب شده‌اند: قیمت بسته‌شدن^۳: این ویژگی نشان‌دهنده قیمت پایانی بیت‌کوین در هر روز است و برای پیش‌بینی قیمت‌های آینده مورد استفاده قرار می‌گیرد. حجم معاملات^۴: این ویژگی میزان معاملات انجام شده در هر روز را نشان می‌دهد و می‌تواند اطلاعات مهمی درباره وضعیت بازار و نوسانات آن ارائه دهد.

- آماده‌سازی و پیش‌پردازش داده‌ها

نرمال‌سازی داده‌ها: داده‌های قیمت و حجم معاملات با استفاده از مقیاس‌گذاری مین‌ماکس^۵ نرمال‌سازی شده‌اند. این فرآیند، داده‌ها را به محدوده بین ۰ و ۱ مقیاس می‌دهد، که به مدل‌های یادگیری ماشین کمک می‌کند تا بهبود عملکرد بهتری داشته باشند.

- تبدیل داده‌ها به دنباله

برای استفاده از داده‌ها در مدل‌های سری زمانی، داده‌های نرمال‌شده به دنباله‌های زمانی با طول مشخص تبدیل می‌شوند. در این پژوهش، طول دنباله‌ها ۳۰ روز تنظیم شده است. این دنباله‌ها شامل قیمت بسته شدن و حجم معاملات برای هر روز در طول یک دوره ۳۰ روزه هستند.

- تقسیم داده‌ها به مجموعه آموزشی و آزمون

داده‌ها به دو مجموعه آموزشی و آزمون تقسیم می‌شوند. ۸۰٪ از داده‌ها برای آموزش مدل‌ها و ۲۰٪ باقیمانده برای ارزیابی عملکرد مدل‌ها استفاده شدند. این تقسیم‌بندی به مدل‌ها اجازه می‌دهد تا بر روی داده‌های آموزشی آموزش ببینند و سپس بر روی داده‌های آزمون ارزیابی شوند. شکل ۲، تقسیم داده‌ها به مجموعه‌های آموزشی و آزمون برای قیمت Close سه رمارز بیت‌کوین، اتریوم و لایت‌کوین را نشان می‌دهد.

۳-۲-۲- مدل‌سازی

مدل‌سازی یکی از مراحل کلیدی در پیش‌بینی سری‌های زمانی است که شامل انتخاب و تنظیم مدل‌های مناسب برای تحلیل داده‌ها می‌شود. در این بخش، به بررسی ساختار مدل، بهینه‌سازی هایپرپارامترها، اثر دوطرفه‌سازی و فرآیند آموزش پرداخته می‌شود.

اصلی برای پیش‌بینی قیمت رمارزها انتخاب شده است. این انتخاب به دلایل زیر توجیه می‌شود.

۳-۱-۱- توانایی مدل‌سازی وابستگی‌های بلندمدت و کوتاه‌مدت

شبکه‌های LSTM و GRU به دلیل ساختار خاص خود قادر به مدل‌سازی وابستگی‌های بلندمدت و الگوهای پیچیده در داده‌های سری زمانی هستند. این ویژگی‌ها به آنها امکان می‌دهند که اطلاعات حیاتی را در طول زمان حفظ کرده و نوسانات پیچیده بازارهای مالی را بهتر پیش‌بینی کنند [۱۹] و [۲۰]. در حالی که LSTM با استفاده از گیت‌های ورودی، خروجی و فراموشی به حفظ و پردازش اطلاعات کمک می‌کند، GRU با استفاده از گیت‌های به‌روزرسانی و بازنشانی، ساختار ساده‌تر و کارآمدتری ارائه می‌دهد [۲۰] و [۲۱].

۳-۱-۲- مزیت دوسویه‌سازی

شبکه‌های عصبی دوسویه (BiGRU و BiLSTM) به‌ویژه برای پیش‌بینی سری‌های زمانی به کار می‌روند زیرا این مدل‌ها می‌توانند داده‌ها را در دو جهت پیشرو و پسرو پردازش کنند [۲۲]. این قابلیت به آنها اجازه می‌دهد که از اطلاعات آینده و گذشته به طور همزمان استفاده کنند و وابستگی‌های زمانی را به‌طور دقیق‌تری مدل‌سازی نمایند. این ویژگی به ویژه در پیش‌بینی قیمت رمارزها که تحت تأثیر عوامل متغیر و نوسانات شدید قرار دارد، بسیار حائز اهمیت است.

۳-۱-۳- کاهش پیچیدگی و زمان محاسباتی

اگرچه شبکه‌های LSTMها به دلیل ساختار پیچیده‌شان به منابع محاسباتی بیشتری نیاز دارند، GRU به دلیل ساختار ساده‌تر خود، زمان محاسباتی و حافظه مورد نیاز را کاهش می‌دهد. این امر به‌ویژه برای تحلیل‌های بزرگ‌مقیاس و پیش‌بینی‌های بلادرنگ مهم است [۱۴] و [۲۳].

۳-۱-۴- عملکرد بهتر در پیش‌بینی سری‌های زمانی

تحقیقات نشان داده‌اند که شبکه‌های LSTM و GRU به دلیل ساختار حافظه‌ای و مکانیزم‌های گیت‌گذاری خود، عملکرد بهتری نسبت به مدل‌های سنتی مانند ARIMA و شبکه‌های عصبی پیش‌خور دارند [۲۴] و [۲۵]. در مقایسه با LSTM، GRU نیز توانسته است در برخی مطالعات عملکرد مشابه یا حتی بهتری از نظر دقت و زمان محاسباتی نشان دهد [۱۹].

۳-۱-۵- موارد کاربرد عملی و تجربی

استفاده از شبکه‌های عصبی دوسویه در پیش‌بینی قیمت رمارزها و سایر کاربردهای پیچیده مانند پردازش زبان طبیعی و پیش‌بینی بار مصرف انرژی، نشان‌دهنده قابلیت‌های بالای این مدل‌ها در تحلیل داده‌های ترتیبی و پیچیده است [۲۵] تا [۲۷]. این امر، مزیت‌های استفاده از این مدل‌ها در تحلیل نوسانات بازار و پیش‌بینی دقیق قیمت‌ها را تأیید می‌کند. در نتیجه، با توجه به توانایی‌های مدل‌های LSTM و GRU، و به‌ویژه نسخه‌های دوطرفه آن‌ها، این پژوهش به دنبال استفاده از این تکنیک‌ها برای بهبود دقت پیش‌بینی قیمت رمارزها است که می‌تواند به بهبود پیش‌بینی‌های مالی و کاهش ریسک‌های مرتبط کمک کند و به تحلیلگران و سرمایه‌گذاران ابزارهای قوی‌تری برای تصمیم‌گیری‌های بهینه ارائه دهد.

1. <https://finance.yahoo.com>

2. USD

3. Close

4. Volume

5. Min-Max Scaler

Date	Open	High	Low	Close	Adj Close	Volume
2016-01-01 00:00:00	430.721	436.246	427.515	434.334	434.334	36278900
2016-01-02 00:00:00	434.622	436.062	431.87	433.438	433.438	30096600
2016-01-03 00:00:00	433.578	433.743	424.706	430.011	430.011	39633800
2016-01-04 00:00:00	430.061	434.517	429.084	433.091	433.091	38477500
2016-01-05 00:00:00	433.069	434.182	429.676	431.96	431.96	34522600

(الف)

Date	Open	High	Low	Close	Adj Close	Volume
2017-11-09 00:00:00	308.645	329.452	307.056	320.884	320.884	893249984
2017-11-10 00:00:00	320.671	324.718	294.542	299.253	299.253	885985984
2017-11-11 00:00:00	298.586	319.453	298.192	314.681	314.681	842300992
2017-11-12 00:00:00	314.69	319.153	298.513	307.908	307.908	1613479936
2017-11-13 00:00:00	307.025	328.415	307.025	316.716	316.716	1041889984

(ب)

Date	Open	High	Low	Close	Adj Close	Volume
2016-01-01 00:00:00	3.47952	3.53102	3.46925	3.50898	3.50898	2791170
2016-01-02 00:00:00	3.51528	3.52712	3.49219	3.50216	3.50216	3020260
2016-01-03 00:00:00	3.504	3.50643	3.45086	3.48307	3.48307	2406150
2016-01-04 00:00:00	3.4791	3.50723	3.47615	3.49539	3.49539	3309740
2016-01-05 00:00:00	3.492	3.50819	3.45372	3.46967	3.46967	2104650

(ج)

شکل ۱: پنج سطر اول مجموعه داده، (الف) بیت کوین، (ب) اتریوم و (ج) لایت کوین.

جدول ۱: مشخصات پارامترهای داده

Open	قیمت باز شدن در ابتدای روز	Close	قیمت بسته شدن در انتهای روز
High	بالاترین قیمت در طول روز	Adj Close	قیمت بسته شدن تعدیل شده که معمولاً برای تقسیم سهام و تقسیم‌های دیگر تنظیم شده است
Low	پایین‌ترین قیمت در طول روز	Volume	حجم معاملات در طول روز

- ساختار مدل

برای پیش‌بینی قیمت رمزارزها، مدل‌های مختلف شبکه‌های عصبی شامل LSTM، GRU، BiLSTM و BiGRU استفاده شده‌اند. در این زمینه، ساختار مدل‌ها شامل لایه‌های مختلفی است که به پردازش داده‌های ورودی و پیش‌بینی قیمت‌ها کمک می‌کند. مدل GRU و LSTM به ترتیب از لایه‌های GRU و LSTM پردازش داده‌های سری زمانی استفاده می‌کنند. این لایه‌ها به مدل کمک می‌کنند تا وابستگی‌های طولانی مدت را در داده‌ها شناسایی کند.

مدل‌های BiLSTM و BiGRU از دوسویه‌سازی بهره می‌برند، به این معنا که مدل به طور همزمان از دو جهت (جلو به عقب و عقب به جلو) اطلاعات را پردازش می‌کند. این امر به مدل اجازه می‌دهد تا از کل زمینه

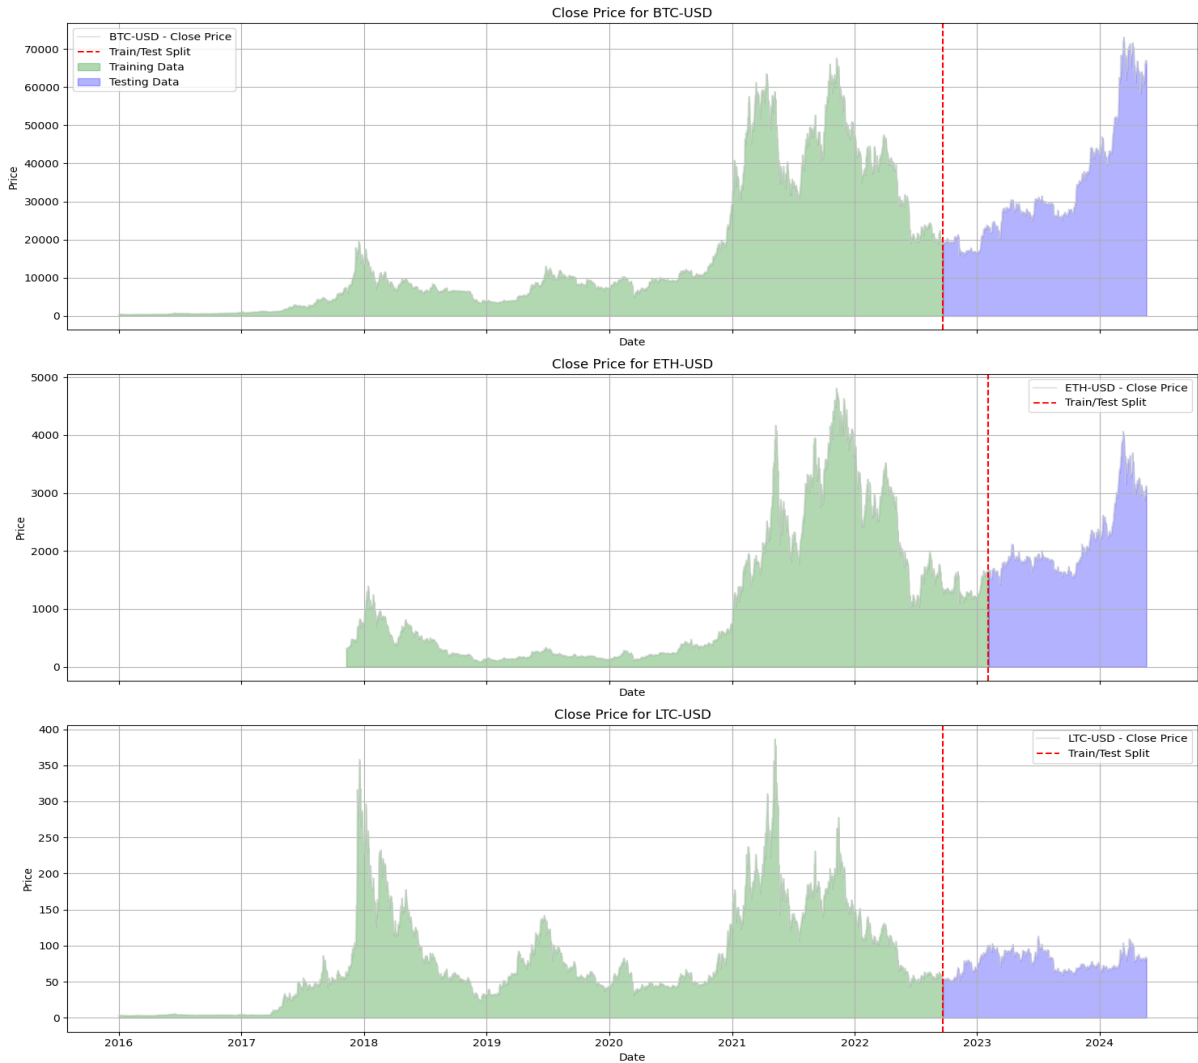
زمانی برای بهبود پیش‌بینی استفاده کند.

۳-۲-۳- بهینه‌سازی هایپر پارامترها

تنظیم هایپر پارامترها برای بهینه‌سازی عملکرد مدل‌ها امری حیاتی است. در این تحقیق، سه روش بهینه‌سازی برای هایپر پارامترها مورد بررسی قرار گرفته است:

- جستجوی شبکه‌ای

این روش به طور سیستماتیک تمامی ترکیبات ممکن هایپر پارامترها را امتحان می‌کند تا بهترین ترکیب را بیابد (روشی زمان‌بر است اما دقت بالایی دارد).



شکل ۲: تقسیم داده‌ها به مجموعه‌های آموزشی و آزمون برای قیمت Close سه رمزارز بیت کوین، اتریوم و لایت کوین.

جدول ۲: مقایسه درصد خطای حاصل از سه روش بهینه‌سازی مختلف برای دو مدل LSTM و GRU

GRU		LSTM		روش بهینه‌سازی هایپرپارامترها	رمز ارز
RMSE%	RMSE (دلار)	RMSE%	RMSE (دلار)		
۹,۰۰	۳۰۳۰	۳,۷۲	۱۲۵۷	جستجوی شبکه‌ای	
۴,۹۳	۱۶۶۰	۷,۳۹	۲۴۹۵	جستجوی اتفاقی CV	BTC
۵,۳۱	۱۷۹۳	۶,۹۱	۲۳۳۳	بهینه‌سازی بیزین	

GRU، روش جستجوی اتفاقی بهترین عملکرد (کمترین درصد خطا) را ارائه داده است، در حالی که برای مدل LSTM، جستجوی عملکرد مناسب‌تری از خود نشان داد. این انتخاب‌ها با هدف دستیابی به بهترین عملکرد و کمترین خطا در مدل‌ها انجام شده‌اند. در تمامی آزمون‌ها نیاز به تعیین مقدار بهینه برای چهار هایپرپارامتر وجود دارد:

تعداد واحدهای مدل^۱ تعیین‌کننده تعداد واحدهای در هر لایه‌ی مدل‌ها است. سه مقدار مختلف شامل ۵۰، ۱۰۰ و ۱۵۰ برای این پارامتر در نظر گرفته شده و جستجو در بین این مقادیر انجام شده است.

- جستجوی اتفاقی

در این روش، نمونه‌ای تصادفی از ترکیبات هایپرپارامترها برای ارزیابی انتخاب می‌شود که می‌تواند زمان جستجو را کاهش دهد و در عین حال نتایج خوبی ارائه دهد.

- جستجوی بیزین

این روش با استفاده از الگوریتم‌های بهینه‌سازی تصادفی و بهینه‌سازی بیزی برای یافتن بهترین هایپرپارامترها استفاده می‌کند.

هر سه روش بهینه‌سازی مذکور برای هر دو مدل LSTM و GRU با استفاده از مجموعه رمزارز BTC مورد آزمون قرار گرفت و آزمون‌ها با انتخاب seed مساوی ۴۲ تکرارپذیر هستند.

در جدول ۲، درصد خطای هر سه روش بهینه‌سازی برای دو مدل استفاده‌شده ثبت شده است که مقایسه‌ی آن‌ها نشان می‌دهد برای مدل

– تبدیل مقیاس

پیش‌بینی‌ها به مقیاس اصلی قیمت‌ها تبدیل شدند تا مقایسه دقیق‌تری با مقادیر واقعی انجام شود.

– مصورسازی نتایج

نتایج پیش‌بینی به صورت نمودارهایی که قیمت‌های پیش‌بینی شده و واقعی را نمایش می‌دهند، ارائه شد. این نمودارها به تحلیل کیفیت پیش‌بینی‌ها و عملکرد مدل کمک می‌کنند.

۵-۲-۳- ابزار استفاده شده

این مدل‌ها بر روی GPUهای ابزار آنلاین گوگل کولب^۷ آموزش دیده اجرا شده‌اند. در اجزای آزمون‌ها، از پایتون^۸ و چندین کتابخانه مانند NumPy^۸ برای محاسبات عددی، پانداس^۹ برای پردازش و تجزیه و تحلیل داده‌ها، مت‌پلات‌لیب^{۱۰} برای ترسیم داده‌ها و کراس^{۱۱} و اسکای‌لرن^{۱۲} برای ساخت و اجرای مدل‌های یادگیری عمیق در پایتون استفاده شد.

۴- نتایج

در این بخش نتایج اجرای آزمون‌ها، در قالب جداول و شکل‌ها ارائه می‌شود. این نتایج به تفکیک برای چهار مدل استفاده شده که هر مدل بر روی سه رمزارز مورد مطالعه (BTC, ETH, LTC) آزمایش شد، ارائه می‌گردد. سپس نتایج مورد بررسی و تحلیل قرار گرفته و با هدف بررسی اثر دوسویه‌سازی بر کاهش خطای پیش‌بینی، خطا و درصد خطای هر مدل را با RMSE, MAE و R-Square و درصد‌های خطای مدل دوسویه‌ی آن مقایسه و تحلیل خواهد شد.

۴-۱- نتایج مدل LSTM

همان‌طور که در بخش ۲ توضیح داده شد، برای مدل LSTM، بهینه‌سازی هایپرپارامترها با استفاده از روش جستجوی شبکه‌ای انجام گرفت و آزمون‌ها با استفاده از مجموعه داده‌های سه رمزارز بیت‌کوین (BTC)، اتریوم (ETH) و لایت‌کوین (LTC) اجرا گردید. نتایج این آزمون‌ها در قالب جدول ۳ ارائه شده است که مقادیر خطا و درصد خطای هر آزمون را بر اساس سه معیار مختلف RMSE, MAE و R-Square نمایش می‌دهد. همچنین، شکل ۳ برای مشاهده تفاوت بین مقادیر واقعی و پیش‌بینی شده قیمت‌ها نمایش داده شده‌اند.

۴-۲- نتایج مدل BiLSTM

برای مدل BiLSTM نیز بهینه‌سازی همچون مدل LSTM هایپرپارامترها با استفاده از روش جستجوی شبکه‌ای انجام گرفت و آزمون‌ها با استفاده از مجموعه داده‌های سه رمزارز بیت‌کوین (BTC)، اتریوم (ETH) و لایت‌کوین (LTC) اجرا گردید. نتایج این تست‌ها در قالب جدول ۴ ارائه شده است که خطا و درصد خطا را بر اساس سه معیار مختلف RMSE, MAE و R-Square نمایش می‌دهد. همچنین، شکل ۴ برای مشاهده تفاوت بین مقادیر واقعی و پیش‌بینی شده قیمت‌ها نمایش داده شده است.

دو مدل بهینه‌ساز^۱ متفاوت برای آموزش مدل مورد بررسی قرار گرفتند: Adam و RMSprop. هر یک از این بهینه‌سازها روش‌های مختلفی برای به‌روزرسانی وزن‌ها در حین آموزش مدل دارند.

پارامتر تعداد تکرار^۲ مشخص می‌کند که مدل چند بار باید بر روی کل داده‌های آموزشی آموزش ببیند. مقادیر ۱۰، ۲۰ و ۳۰ برای این پارامتر در نظر گرفته شده و مورد جستجو قرار گرفت.

اندازه دسته^۳ اندازه‌ی دسته‌های داده‌ای را که مدل در هر مرحله از آموزش مشاهده می‌کند تعیین می‌کند. مقادیر ۱۶، ۳۲ و ۶۴ برای این پارامتر بررسی شدند.

۴-۲-۳- فرآیند آموزش و ارزیابی مدل

فرآیند آموزش و ارزیابی مدل شامل مراحل زیر است:

– آموزش مدل

مدل‌ها با استفاده از داده‌های آموزشی و هایپرپارامترهای بهینه‌شده آموزش داده شدند. این مرحله شامل تنظیم وزن‌های مدل برای به حداقل رساندن خطاهای پیش‌بینی است.

– پیش‌بینی و ارزیابی

پس از آموزش مدل، پیش‌بینی‌ها بر روی داده‌های تست انجام شد. نتایج پیش‌بینی‌ها با مقادیر واقعی مقایسه شده و خطاهای مدل به کمک معیارهای RMSE^۴، MAE^۵ و R-Square^۶ و همچنین درصد خطای RMSE و MAE محاسبه شد. هر چه مقادیر RMSE، MAE و درصد خطا کمتر باشد و مقدار R^۲ به یک نزدیک‌تر باشد، عملکرد مدل پیش‌بینی بهتر است.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (A_t - P_t)^2}{n}} \quad (1)$$

$$RMSE \% = \frac{RMSE}{Mean \text{ of Actual Prices}} \quad (2)$$

که در آن A_t و P_t به ترتیب مقادیر پیش‌بینی شده و واقعی و n تعداد گام‌های زمانی است.

$$MAE = \frac{\sum_{t=1}^n |A_t - P_t|}{n} \quad (3)$$

$$MAE \% = \frac{MAE}{Mean \text{ of Actual Prices}} \quad (4)$$

$$R - Square = 1 - \frac{\sum_{t=1}^n (A_t - P_t)^2}{\sum_{t=1}^n (A_t - \bar{A}_t)^2} \quad (5)$$

که در آن \bar{A} میانگین مقادیر واقعی است.

7. <https://colab.research.google.com>

8. NumPy

9. Pandas

10. Matplotlib

11. Keras

12. Sklearn

1. Model Optimizer

2. Epochs

3. Batch Size

4. Root Mean Squared Error

5. Mean Absolute Error


6. Coefficient of Determination



(الف)



(ب)



(ج)

شکل ۳: مقایسه قیمت واقعی و قیمت پیش‌بینی شده با مدل LSTM، (الف) بیت کوین، (ب) اتریوم و (ج) لایت کوین.

جدول ۳: مقادیر خطا و درصد خطا برای پیش‌بینی قیمت رمز ارزها با مدل LSTM.


R-Square	MAE%	MAE (دلار)	RMSE%	RMSE (دلار)	مدل	رمز ارز
۰.۹۸	۳.۶۸	۱۲۳۹.۸	۳.۷۲	۱۲۵۷	LSTM	BTC
۰.۹۷	۳.۶۹	۸۰.۳۲	۴.۸۳	۱۰۵.۲۶		ETH
۰.۹۰	۴.۰۹	۳.۱۸	۴.۵۷	۳.۵۵		LTC



(الف)



(ب)



(ج)

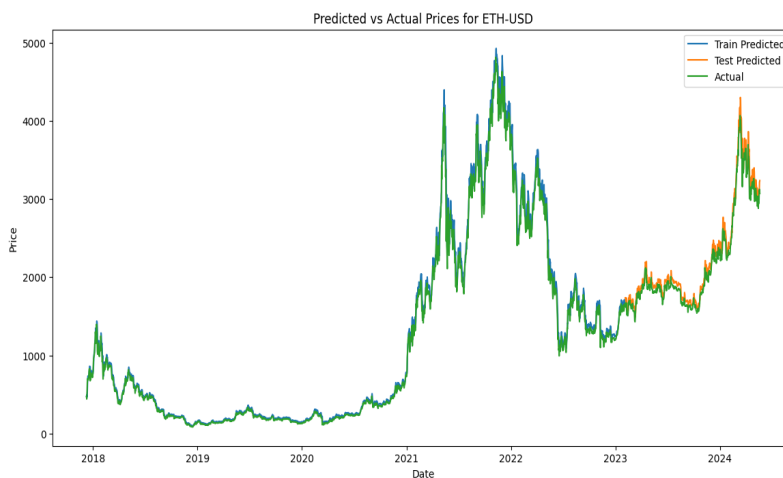
شکل ۴: مقایسه قیمت واقعی و قیمت پیش‌بینی شده با مدل BiLSTM، (الف) بیت کوین، (ب) اتریوم و (ج) لایت کوین.

جدول ۴: مقادیر خطا و درصد خطا برای پیش‌بینی قیمت رمزارزها با مدل BiLSTM.


R-Square	MAE%	MAE (دلار)	RMSE%	RMSE (دلار)	مدل	رمز ارز
۰.۹۹	۳.۲۸	۱۱۰۵.۵۶	۳.۲۲	۱۰۸۴	BiLSTM	BTC
۰.۹۷	۳.۴۸	۷۵.۸۰	۳.۹۴	۷۶.۸۵		ETH
۰.۹۰	۳.۸۷	۳	۳.۹۹	۳.۱۱		LTC



(الف)



(ب)



(ج)

شکل ۵: مقایسه قیمت واقعی و قیمت پیش‌بینی شده با مدل GRU، (الف) بیت کوین، (ب) اتریوم و (ج) لایت کوین.

جدول ۵: مقادیر خطا و درصد خطا برای پیش‌بینی قیمت رمزارزها با مدل GRU.

R-Square	MAE%	MAE (دلار)	RMSE%	RMSE (دلار)	مدل	رمز ارز
۰.۹۹	۳.۹۸	۸۳۱.۰۲	۴.۹۳	۱۶۶۰	GRU	BTC
۰.۹۳	۶.۴۵	۱۴۰.۲۹	۵.۱۵	۱۱۲		ETH
۰.۹۲	۳.۸۵	۳	۴.۷۶	۳.۷۱		LTC

۳-۴- نتایج مدل GRU

LSTM می‌تواند به طور مؤثری درصد خطای پیش‌بینی را کاهش دهد و به دستیابی به هدف اصلی تحقیق کمک کند.

۳-۵-۴- تفسیر نتایج مدل GRU

مدل GRU که به منظور کاهش پیچیدگی محاسباتی و افزایش سرعت آموزش طراحی شده، نتایج متوسطی ارائه کرده است. با توجه به جدول ۷، میانگین خطای دو معیار مختلف برای بیت‌کوین در این مدل برابر $54/1245\%$ بوده و میانگین درصد خطا نیز $4/46\%$ است که نسبت به مدل‌های LSTM و BiLSTM دقت کمتری دارد. این موضوع ممکن است به دلیل ساختار ساده‌تر GRU و عدم استفاده از دوطرفه‌سازی باشد. این نتایج نشان می‌دهد که برای دستیابی به دقت بالاتر، استفاده از روش‌های پیشرفته‌تری مانند دوطرفه‌سازی ضروری است.

۴-۵-۴- تفسیر نتایج مدل BiGRU

مدل BiGRU که ترکیبی از مزایای دوطرفه‌سازی و سادگی GRU را ارائه می‌دهد، نتایج بهتری نسبت به GRU ارائه کرده است. همان‌طور که در جدول ۷ مشاهده می‌شود، میانگین خطای معیارهای مختلف برای بیت‌کوین برابر با $41/1073\%$ و میانگین درصد خطای دو معیار مختلف $3/19$ است که نشان‌دهنده بهبود قابل توجه نسبت به مدل GRU است. این نتایج نشان می‌دهد که دوطرفه‌سازی حتی در مدل‌های ساده‌تری مانند GRU نیز می‌تواند تأثیر مثبتی بر دقت پیش‌بینی داشته باشد. این مقدار به مقدار مشابه به‌دست‌آمده در مدل BiLSTM نیز بسیار نزدیک است.

۵- ارزیابی نتایج

همان‌طور که در جدول ۸ مشاهده می‌شود، نتایج این تحقیق در مقایسه با تحقیقات مشابه در حوزه پیش‌بینی قیمت رمزارزها، نشان‌دهنده عملکرد قابل توجهی است. مدل ما به‌طور میانگین توانسته برای رمزارزهای BTC، ETH و LTC به ترتیب میزان خطای $3/19\%$ ، $3/94\%$ و $3/99\%$ را ثبت کند. این مقادیر در مقایسه با تحقیقاتی مانند [۲۲] و [۲۳] که میزان خطای بالاتری را گزارش کرده‌اند، نشان‌دهنده دقت بالاتر مدل ما است. به عنوان مثال، در تحقیق [۲۲] میزان خطای پیش‌بینی برای BTC و ETH به ترتیب $3/5\%$ و $5/7\%$ بوده و در پژوهش [۲۳] خطای BTC و ETH به ترتیب $2/3\%$ و $4/2\%$ گزارش شده است.

همچنین، تحقیق [۱۰] برای BTC و LTC نتایجی با خطای مشابه و یا کمی بهتر، و برای ETH نتایج بهتری با خطای $1/24\%$ را نشان می‌دهد. با این حال، نتایج ما در اکثر موارد به رقبای نزدیک یا بهتر است و در دسته‌بندی‌های مختلف رمزارزها، مدل ارائه‌شده ما کارایی بالایی را نشان داده است. این موضوع بیانگر قدرت و دقت مدل پیشنهادی در پیش‌بینی قیمت رمزارزها است.

نتایج تحقیق نشان می‌دهد که دوسویه‌سازی شبکه‌های عصبی LSTM و GRU به طور مؤثری به کاهش درصد خطای پیش‌بینی قیمت رمزارزها کمک می‌کند.

همان‌طور که در جدول ۷ نیز قابل مشاهده است، مدل‌های BiLSTM و BiGRU به عنوان بهترین مدل‌ها با کمترین درصد خطا، نشان می‌دهد که این تکنیک‌ها می‌توانند بهبود قابل توجهی در دقت پیش‌بینی‌ها ایجاد کنند. این یافته‌ها تأیید می‌کند که استفاده از دوسویه‌سازی در شبکه‌های عصبی یادگیری عمیق، استراتژی مؤثری برای بهبود دقت پیش‌بینی سری‌های زمانی پیچیده مانند قیمت رمزارزها است.

همان‌طور که در بخش ۳ توضیح داده شد، برای مدل GRU بهینه‌سازی هایپرپارامترها با استفاده از روش جستجوی اتفاقی CV انجام شد و آزمون‌ها با استفاده از مجموعه داده‌های سه رمزارز بیت‌کوین (BTC)، اتریوم (ETH) و لایت‌کوین (LTC) اجرا گردید. نتایج این آزمون‌ها در قالب جدول ۵ ارائه شده است که خطا و درصد خطا را بر اساس سه معیار مختلف RMSE، MAE و R-Square نمایش می‌دهد. همچنین، شکل ۵ برای مشاهده تفاوت بین مقادیر واقعی و پیش‌بینی‌شده قیمت‌ها نمایش داده شده است.

۴-۴- نتایج مدل BiGRU

برای مدل BiGRU نیز همچون مدل GRU بهینه‌سازی هایپرپارامترها با استفاده از روش جستجوی اتفاقی CV انجام شد و تست‌ها با استفاده از مجموعه داده‌های سه رمزارز بیت‌کوین (BTC)، اتریوم (ETH) و لایت‌کوین (LTC) اجرا گردید. نتایج این تست‌ها در قالب جدول ۶ ارائه شده است که خطا و درصد خطا را بر اساس سه معیار مختلف RMSE، MAE و R-Square نمایش می‌دهد. همچنین، شکل ۶ تفاوت بین مقادیر واقعی و پیش‌بینی‌شده قیمت‌ها را نمایش می‌دهد.

۵-۴- تفسیر نتایج

در این بخش، نتایج به دست آمده از چهار مدل LSTM، BiLSTM، GRU و BiGRU با تأکید بر هدف اصلی تحقیق که کاهش درصد خطای پیش‌بینی قیمت رمزارزها از طریق دوسویه‌سازی شبکه‌های عصبی یادگیری عمیق است، مورد بررسی قرار می‌گیرد. به این ترتیب، ارزیابی عملکرد مدل‌ها نه تنها به مقادیر خطا و درصد خطا، بلکه به میزان تأثیر دوسویه‌سازی^۱ در بهبود دقت پیش‌بینی‌ها توجه خواهد داشت.

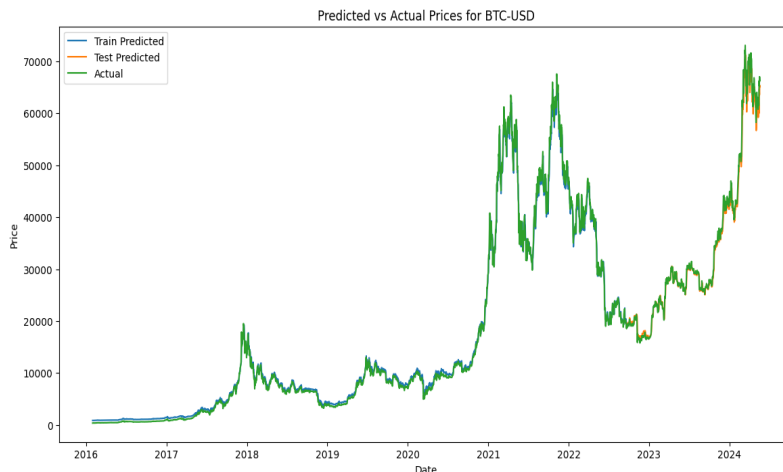
۱-۵-۴- تفسیر نتایج مدل LSTM

مدل LSTM به عنوان یک مدل پایه و غیر دوسویه، برای پیش‌بینی قیمت رمزارزها استفاده شده است. با توجه به جدول ۷، این مدل در پیش‌بینی قیمت بیت‌کوین با میانگین خطای برابر با $4/1248\%$ و میانگین درصد خطای $3/72\%$ عملکرد نسبتاً خوبی داشته است. با این حال، نتایج برای اتریوم و لایت‌کوین با درصد خطاهای بالاتری همراه است، که نشان‌دهنده محدودیت‌های مدل LSTM در دستیابی به دقت مطلوب در پیش‌بینی قیمت رمزارزهای مختلف است. این نتایج تأکید می‌کند که مدل‌های پایه‌ای همچون LSTM ممکن است نیاز به بهبودهای بیشتری داشته باشند تا بتوانند دقت پیش‌بینی را افزایش دهند.

۲-۵-۴- تفسیر نتایج مدل BiLSTM

مدل BiLSTM که از دوسویه‌سازی در شبکه‌های عصبی بهره می‌برد، به طور قابل توجهی دقت پیش‌بینی را بهبود بخشیده است. همان‌طور که در جدول ۷ مشاهده می‌شود، این مدل در پیش‌بینی قیمت بیت‌کوین با میانگین خطای برابر با $8/1094\%$ و میانگین درصد خطای $3/25\%$ نسبت به مدل LSTM عملکرد بهتری داشته است. کاهش درصد خطا برای اتریوم و لایت‌کوین نیز نشان‌دهنده تأثیر مثبت دوطرفه‌سازی بر دقت مدل است. این نتایج نشان می‌دهد که دوسویه‌سازی در مدل‌های


1. Bidirectional



(الف)



(ب)



(ج)

شکل ۶: مقایسه قیمت واقعی و قیمت پیش‌بینی شده با مدل BiGRU. (الف) بیت کوین، (ب) اتریوم و (ج) لایت کوین.

جدول ۶: مقادیر خطا و درصد خطا برای پیش‌بینی قیمت رمزارزها با مدل BiGRU.

R-Square	MAE%	MAE (دلار)	RMSE%	RMSE (دلار)	مدل	رمز ارز
۰.۹۹	۲.۵۴	۸۵۶.۲۸	۳.۸۳	۱۲۹۰	BiGRU	BTC
۰.۹۶	۴.۰۶	۸۸.۴۴	۴.۰۵	۸۸.۲۶		ETH
۰.۹۴	۲.۷۶	۲.۱۴	۴.۶۶	۳.۶۲		LTC

جدول ۷: مقایسه میانگین مقادیر خطا و درصد خطا با سه معیار مختلف (RMSE, MAE, R-Square) برای پیش‌بینی قیمت رمزارزها با چهار مدل LSTM, BiLSTM, GRU و BiGRU.

BiGRU		GRU		BiLSTM		LSTM	
ضریب میانگین	میانگین خطا (دلار)	ضریب میانگین	میانگین خطا (دلار)	ضریب میانگین	میانگین خطا (دلار)	ضریب میانگین	میانگین خطا (دلار)
---	---	---	---	۰.۹۹	۱۲۴۵.۵۴	۰.۹۹	۱۲۴۸.۴
۰.۹۹	۳٪	۱۰۷۳/۴۱	۰.۹۹	۴/۴۶	۱۲۴۵.۵۴	---	---
---	---	---	---	۰.۹۷	۱۲۶/۱۵	۰.۹۷	۹۲/۷۹
۰.۹۶	۴٪	۸۸/۳۵	۰.۹۳	۵/۸۳	۱۲۶/۱۵	---	---
---	---	---	---	۰.۹۱	۳/۳۶	۰.۹۱	۳/۳۷
۰.۹۴	۳/۷۱	۲/۸۸	۰.۹۲	۴/۳۱	۳/۳۶	---	---

جدول ۸: مقایسه نتایج روش پیشنهادی با نتایج سایر تحقیقات

مرجع تحقیق	رمزارز	بهترین درصد خطای گزارش شده (MAE% یا RMSE%)
[۲۲] سال ۲۰۲۲	BTC	۳.۵۰
[۲۲] سال ۲۰۲۲	ETH	۵.۷۰
[۲۳] سال ۲۰۲۲	BTC	۳.۳۰
[۲۳] سال ۲۰۲۲	ETH	۴.۲۰
[۱۲] سال ۲۰۲۳	BTC	۳.۶۰
[۱۲] سال ۲۰۲۳	ETH	۱.۲۴
[۱۲] سال ۲۰۲۳	LTC	۴.۱۰
روش پیشنهادی	BTC	۳.۲۲
روش پیشنهادی	ETH	۳.۹۴
روش پیشنهادی	LTC	۳.۹۹

دیگر نظیر حجم معاملات، شاخص‌های اقتصادی یا اخبار بازار، در مدل لحاظ نشده‌اند. این موارد، ضرورت تحقیقات بیشتر برای بهبود تعمیم‌پذیری و تقویت عملکرد مدل‌ها در شرایط واقعی بازار را نشان می‌دهد.

۶- نتیجه‌گیری

در این پژوهش به روش جدیدی برای پیش‌بینی قیمت رمزارزها با استفاده از شبکه‌های LSTM و GRU پرداخته و رویکرد دوسویه‌سازی این شبکه‌ها را با تاکید به انتخاب بهینه‌های پیرامترها به منظور کاهش خطای پیش‌بینی و افزایش دقت ارائه می‌شود. با توجه به نتایج به دست آمده از این تحقیق، پیشنهاداتی برای تحقیقات آینده به شرح زیر ارائه می‌شود. پیشنهاد می‌شود که در تحقیقات آینده، سایر ساختارهای شبکه‌های عصبی عمیق مانند مدل‌ها^۱ و شبکه‌های توجه‌محور^۲ مورد بررسی قرار گیرند تا مشخص شود که آیا این مدل‌ها می‌توانند عملکرد بهتری نسبت به مدل‌های LSTM و GRU در پیش‌بینی سری‌های زمانی مالی ارائه دهند.

تحقیقات آینده می‌توانند بر روی استفاده از داده‌های متنوع‌تر و بزرگ‌تر برای مدل‌سازی و پیش‌بینی قیمت رمزارزها متمرکز شوند. بررسی داده‌های بازارهای دیگر مانند فارکس یا سهام نیز می‌تواند به گسترش دامنه کاربردهای این روش‌ها کمک کند. توسعه مدل‌های ترکیبی که از

در ادامه، نتایج حاصل از پژوهش به طور خلاصه بررسی، جمع‌بندی و نتیجه‌گیری می‌شوند. هدف اصلی این تحقیق، کاهش درصد خطای پیش‌بینی قیمت رمزارزها با استفاده از دوسویه‌سازی شبکه‌های عصبی یادگیری عمیق (LSTM و GRU) بود. برای این منظور، چهار مدل مختلف شامل LSTM، BiLSTM، GRU و BiGRU مورد بررسی و ارزیابی قرار گرفتند. نتایج به دست آمده از این مدل‌ها نشان‌دهنده کارایی و دقت هر یک در پیش‌بینی قیمت سه رمزارز بیت‌کوین (BTC)، اتریوم (ETH) و لایت‌کوین (LTC) بودند.

نتایج نشان داد که مدل BiLSTM در مقایسه با مدل LSTM عملکرد بهتری در پیش‌بینی قیمت رمزارزها داشت. این موضوع به ویژه در کاهش مقادیر سه معیار مختلف خطا و درصد خطای پیش‌بینی مشهود بود. برای مثال، در پیش‌بینی قیمت بیت‌کوین (BTC)، مدل BiLSTM با RMSE برابر ۱۰۸۴ و درصد خطای ۳/۲۲٪ عملکرد بهتری نسبت به مدل LSTM با RMSE برابر ۱۲۵۷ و درصد خطای ۳/۷۲٪ داشت. به طور مشابه، در پیش‌بینی قیمت اتریوم (ETH) و لایت‌کوین (LTC) نیز مدل BiLSTM دقت بالاتری نسبت به مدل LSTM نشان داد.

در مورد مدل‌های GRU و BiGRU نیز نتایج مشابهی مشاهده شد. مدل BiGRU در مقایسه با GRU دقت بالاتری در پیش‌بینی قیمت رمزارزها داشت. به عنوان مثال، در پیش‌بینی قیمت بیت‌کوین (BTC)، مدل BiGRU با RMSE برابر ۱۲۹۰ و درصد خطای ۳/۸۳٪ عملکرد بهتری نسبت به مدل GRU با RMSE برابر ۱۶۶۰ و درصد خطای ۴/۹۳٪ داشت. این بهبود در دقت پیش‌بینی برای سایر رمزارزها مانند اتریوم (ETH) و لایت‌کوین (LTC) نیز مشاهده شد.

به طور کلی، دوسویه‌سازی شبکه‌های عصبی (BiGRU و BiLSTM) دقت پیش‌بینی قیمت رمزارزها را افزایش و درصد خطای پیش‌بینی را کاهش داد. این نتایج نشان می‌دهد که دوسویه‌سازی شبکه‌های عصبی می‌تواند به عنوان یک رویکرد موثر برای بهبود دقت پیش‌بینی سری‌های زمانی مالی، به ویژه در بازار رمزارزها، و در جهت کاهش ریسک سرمایه‌گذاری مورد استفاده قرار گیرد.

با وجود نتایج موفق شبکه‌های دو سویه LSTM و BiGRU در بهبود دقت پیش‌بینی قیمت رمزارزها، این پژوهش با محدودیت‌هایی روبرو است. نخست، مدل‌های ارائه‌شده عمدتاً بر داده‌های تاریخی تکیه دارند و در نتیجه نمی‌توانند تاثیر رویدادهای غیرمنتظره، اخبار و تحولات ناگهانی بازار را به درستی پیش‌بینی کنند. علاوه بر این، کیفیت و جامعیت داده‌های ورودی نقش تعیین‌کننده‌ای در عملکرد مدل‌ها دارد و وجود نویز یا داده‌های ناقص می‌تواند منجر به کاهش دقت پیش‌بینی شود. در نهایت، این پژوهش عمدتاً متغیرهای قیمتی را لحاظ نموده و برخی عوامل موثر

- directional LSTM and trend-preserving model bias correction," *IEEE Access*, vol. 11, pp. 65700-65710, 2023.
- [15] N. Hussein and A. M. Abdulazeez, "Bitcoin price prediction using hybrid LSTM-GRU models," *The Indonesian Journal of Computer Science*, vol. 13, no. 1, pp. 94-101, 2024.
- [16] M. H. A. Hadi, N. A. Ramli, and Q. U. Islam, "Predicting Bitcoin and Ethereum prices using long short-term memory and gated recurrent unit," *Data Analytics and Applied Mathematics*, vol. 4, no. 2, pp. 8-17, 2023.
- [17] P. Pandey and G. Sharma, "Effective price prediction of cryptocurrencies using CNN-based dual directional model," *Science & Technology Asia*, vol. 30, no. 1, pp. 201-219, Jan./Mar. 2025.
- [18] X. Wang, I. Cretu, and H. Meng, "A cryptocurrency price forecasting model by integrating empirical mode decomposition and LSTM neural networks," *Artificial Intelligence and Applications*, vol. 3, no. 3, pp. 305-315, Mar. 2025.
- [19] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [20] K. Cho, et al., Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation, arXiv preprint arXiv:1406.1078, 2014.
- [21] W. Zheng and G. Chen, "An accurate GRU-based power time-series prediction approach with selective state updating and stochastic optimization," *IEEE Trans. on Cybernetics*, vol. 52, no. 12, pp. 13902-13914, Dec. 2022.
- [22] S. Hansun, A. Wicaksana, and A. Q. Khaliq, "Multivariate cryptocurrency prediction: comparative analysis of three recurrent neural networks approaches," *Journal of Big Data*, vol. 9, no. 1, Article ID: 50, 2022.
- [23] S. Ozturk Birim, "An analysis for cryptocurrency price prediction using LSTM, GRU, and the bi-directional implications," In S. Karabulut (ed.), *Developments in Financial and Economic Fields at the National and Global Scale*, pp. 377-392, 2022.
- [24] T. Fischer and C. Krauss, "Deep learning with long short-term memory networks for financial market predictions," *European Journal of Operational Research*, vol. 270, no. 2, pp. 654-669, Oct. 2018.
- [25] S. Siami-Namini, N. Tavakoli, and A. S. Namin, "A comparison of ARIMA and LSTM in forecasting time series," in *Proc. 17th IEEE Int. Conf. on Machine Learning and Applications*, pp. 1394-1401, Orlando, FL, USA, 17-20 Dec. 2018.
- [26] S. McNally, J. Roche, and S. Caton, "Predicting the price of bitcoin using machine learning," in 2018 26th Euromicro International Conference on Parallel, Distributed and Network-Based Processing (PDP), 2018.
- [27] D. Bahdanau, K. Cho, and Y. Bengio, *Neural Machine Translation by Jointly Learning to Align and Translate*, arXiv preprint arXiv:1409.0473, 2014.

فناشه کاظم زاده تحصیلات خود را در سال ۱۳۸۶ در کارشناسی مهندسی متالورژی خود از دانشگاه فردوسی مشهد و مقطع کارشناسی ارشد خود را در رشته مهندسی برق گرایش مخابرات سیستم در دانشگاه بین المللی امام رضا (ع) در سال ۱۴۰۲ به پایان رسانده است. زمینه های تحقیقاتی مورد علاقه ایشان عبارتند از: یادگیری ماشین و هوش مصنوعی.

مسعود هوشمند تحصیلات خود را در مقاطع کارشناسی، کارشناسی ارشد و دکتری از دانشگاه فردوسی، تهران و فردوسی در رشته مهندسی برق- الکترونیک به ترتیب در سال های ۱۳۷۷ و ۱۳۷۹ و ۱۳۹۰ به پایان رسانده است. هم اکنون زمینه های تحقیقاتی مورد علاقه ایشان عبارتند از: هوش مصنوعی و سیستم های نهفته.

منیره هوشمند تحصیلات خود را در مقاطع کارشناسی، کارشناسی ارشد و دکتری در رشته مهندسی برق- الکترونیک از دانشگاه فردوسی به ترتیب در سال های ۱۳۸۵، ۱۳۸۷ و ۱۳۹۰ به پایان رسانده است و هم اکنون دانشیار گروه مهندسی برق دانشگاه بین المللی امام رضا (ع) است. زمینه های تحقیقاتی مورد علاقه ایشان عبارتند از: نظریه اطلاعات و محاسبات کوانتومی، یادگیری ماشین و هوش مصنوعی.

ترکیب ویژگی های مدل های مختلف بهره می برند، می تواند به بهبود دقت پیش بینی ها کمک کند. برای مثال، ترکیب مدل های آماری سنتی با شبکه های عصبی عمیق می تواند به عنوان یک رویکرد جدید مطرح شود. تحقیقات آینده می توانند بر روی بررسی تأثیر عوامل خارجی مانند اخبار اقتصادی، تغییرات سیاسی و رویدادهای جهانی بر پیش بینی قیمت رمزارزها تمرکز کنند. این موضوع می تواند به بهبود دقت و کاربردپذیری مدل های پیش بینی کمک کند. بهینه سازی های جدید و پیشرفته تر می توانند به بهبود عملکرد مدل های دوطرفه کمک کنند. مطالعه بر روی الگوریتم های بهینه سازی مختلف مانند بهینه سازی های تکاملی یا الگوریتم های جستجوی تصادفی می تواند به نتایج بهتری منجر شود.

مراجع

- [1] A. Gasparin, S. Lukovic, and C. Alippi, "Deep learning for time series forecasting: The electric load case," *CAAI Trans. on Intelligence Technology*, vol. 7, no. 1, pp. 1-25, Mar. 2022.
- [2] M. Shin, D. Mohaisen, and J. Kim, "Bitcoin price forecasting via ensemble-based LSTM deep learning networks," in *Proc. Int. Conf. on Information Networking*, pp. 603-608, Jeju Island, South Korea, 13-16 Jan. 2021.
- [3] S. Yang, X. Yu, and Y. Zhou, "LSTM and GRU neural network performance comparison study: Taking Yelp review dataset as an example," in *Proc. Int. Workshop on Electronic Communication and Artificial Intelligence*, pp. 98-101, Shanghai, China, 12-14 Jun. 2020.
- [4] T. Shintate and L. Pichl, "Trend prediction classification for high frequency bitcoin time series with deep learning," *Journal of Risk and Financial Management*, vol. 12, no. 1, Article ID: 17, Mar. 2019.
- [5] K. A. Althelaya, E.-S. M. El-Alfy, and S. Mohammed, "Stock market forecast using multivariate analysis with bidirectional and stacked (LSTM, GRU)," in *Proc. 21st Saudi Computer Society National Computer Conf.*, 7 pp., Riyadh, Saudi Arabia, 25-26 Apr. 2018.
- [6] A. Singh, A. Kumar, and Z. Akhtar, "Bitcoin price prediction: A deep learning approach," in *Proc. 8th Int. Conf. on Signal Processing and Integrated Networks*, pp. 1053-1058, Noida, India, 26-27 Aug. 2021.
- [7] G. Liu, F. Xiao, C. -T. Lin, and Z. Cao, "A fuzzy interval time-series energy and financial forecasting model using network-based multiple time-frequency spaces and the induced-ordered weighted averaging aggregation operation," *IEEE Trans. on Fuzzy Systems*, vol. 28, no. 11, pp. 2677-2690, Nov. 2020.
- [8] R. Reyhani and A. M. E. Moghadam, "A heuristic method for forecasting chaotic time series based on economic variables," in *Proc. 6th Int. Conf. on Digital Information Management*, pp. 300-304, Melbourne, Australia, 26-28 Sept. 2011.
- [9] W. He, et al., "Applying multiple time series data mining to large-scale network traffic analysis," in *Proc. IEEE Conf. on Cybernetics and Intelligent Systems*, pp. 394-399, Chengdu, China, 21-24 Sept. 2008.
- [10] J. Bergstra and Y. Bengio, "Random search for hyper-parameter optimization," *Journal of Machine Learning Research*, vol. 13, pp. 281-305, 2012.
- [11] J. Snoek, H. Larochelle, and R. P. Adams, "Practical Bayesian optimization of machine learning algorithms," in *Proc. 26th Int. Conf. on Neural Information Processing Systems*, vol. 2, pp. 2951-2959, Lake Tahoe, NV, USA, 3-6 Dec. 2012.
- [12] P. L. Seabe, C. R. B. Moutsinga, and E. Pindza, "Forecasting cryptocurrency prices using LSTM, GRU, and bi-directional LSTM: a deep learning approach," *Fractal and Fractional*, vol. 7, no. 2, Article ID: 203, Feb. 2023.
- [13] M. J. Hamayel and A. Y. Owda, "A novel cryptocurrency price prediction model using GRU, LSTM and bi-LSTM machine learning algorithms," *AI*, vol. 2, no. 4, pp. 477-496, Dec. 2021.
- [14] M. Rafi, et al., "Enhancing cryptocurrency price forecasting accuracy: A feature selection and weighting approach with bi-