

## پیش‌بینی قیمت ارزهای دیجیتال با استفاده از الگوریتم حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای

همایون موتمنی<sup>۱</sup>، محمد محمدجان زاده<sup>۲</sup>

<sup>۱</sup> عضو هیات علمی دانشگاه آزاد اسلامی واحد ساری

<sup>۲</sup> کارشناسی ارشد رشته مهندسی کامپیوتر گرایش هوش مصنوعی و رباتیک دانشگاه روزبهان

### چکیده

ظهور رمزارزهای مختلف، سرمایه‌گذاری قابل توجهی را در سال‌های اخیر با افزایش نمایی در سرمایه بازار و حجم تجارت جذب کرده است. با این حال، بازار ارزهای دیجیتال بسیار پر نوسان است و با مجموعه داده‌های ناهمگن قابل توجهی که با تعاملات پیچیده بین پیش‌بینی‌کننده‌ها مشخص می‌شود، پر شده است، که ممکن است برای تکنیک‌های مرسوم دستیابی به نتایج بهینه دشوار باشد. علاوه بر این، نوسانات بطور قابل توجهی بر تصمیمات سرمایه‌گذاری توسط سرمایه‌گذاران خرد و کلان تأثیر می‌گذارد. از این رو، می‌توان عنوان کرد که پیش‌بینی قیمت ارزهای دیجیتال به دلیل نوسانات، بی‌ثباتی و عوامل دیگر چالش برانگیز بوده است. سرمایه‌گذاران و معامله‌گران به دنبال روشی مطمئن برای اطلاع از روند بازار و قیمت‌ها بوده‌اند و در حالی که تحقیقات زیادی با استفاده از یادگیری عمیق انجام شده است، نتایجی که برای آن‌ها از آنچه که سرمایه‌گذاران می‌توانستند آن را قوی‌تر نامیده باشند، کمتر است. این پژوهش نتایج بسیاری از کارهای انجام شده را بررسی کرد و از ترکیب دو الگوریتم یادگیری عمیق یعنی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای برای پیش‌بینی قیمت‌های آتی یک مورد از رایج‌ترین دارایی‌های رمزنگاری یعنی بیت کوین پیشنهاد کرد. الگوریتم واحد بازگشتی دروازه‌ای فرآیند استخراج ویژگی‌های موثر را انجام می‌دهد و سپس از الگوریتم حافظه طولانی کوتاه‌مدت برای پیش‌بینی قیمت براساس ویژگی‌های انتخاب شده استفاده می‌شود. آزمایش در محیط پایتون انجام شد و عملکرد مدل پیشنهادی و مقایسه آن با دیگر راهکارها براساس معیارهای ریشه میانگین مربعات خطا و میانگین درصد خطای مطلق ارزیابی شد و نتایج دبست آمده نشان داد که روش پیشنهادی پژوهش توانسته پیش‌بینی بهتری را نسبت به دیگر مدل‌ها داشته باشد. و به نوعی اختلاف مقادیر پیش‌بینی شده با مقادیر واقعی در مدل پیشنهادی کمتر بوده است.

**کلمات کلیدی:** پیش‌بینی قیمت، ارزهای دیجیتال، یادگیری عمیق، واحد بازگشتی دروازه‌ای، حافظه طولانی کوتاه‌مدت.

## مقدمه

در نوامبر ۲۰۰۸، مشخصات ساختاری سیستماتیک بیت کوین<sup>۱</sup> توسط شخص یا گروهی ناشناس با نام مستعار ساتوشی ناکاموتو منتشر شد. از آن زمان تاکنون، با وجود معرفی هزاران ارز دیجیتال<sup>۲</sup> جدید و نوسانات فراوان در قیمت آن، بیت کوین همچنان محبوب ترین و با ارزش ترین ارز دیجیتال در جهان است. علاوه بر این، مجموع ارزش بازار همه ارزهای دیجیتال فعال، از جمله بیت کوین، بیش از ۱۴۰ میلیارد دلار آمریکا است [۱]. حتی اگر تحقیقات منتشر شده در مورد مفاهیم مشابه قبل از اختراع بیت کوین وجود داشته است، تازگی بیت کوین و ارزهای دیجیتال متعاقب آن این است که آنها مشکل دوگانه خرج کردن را بدون داشتن منبع معتبر مرکزی حل می کنند. همه تراکنش ها در یک دفتر کل توزیع شده به نام بلاک چین<sup>۳</sup> ذخیره می شوند که تغییر آن از نظر محاسباتی غیرعملی است. اگرچه در ابتدا برای حل مشکل هزینه مضاعف در ارزهای دیجیتال معرفی شد، فناوری بلاک چین از آن زمان برای سایر زمینه های کاربردی مانند سیستم های پایگاه داده و وب غیرمتمرکز استفاده شده است [۲]. بلاک چین، فناوری که زیربنای سیستم ارزهای دیجیتال بیت کوین است، به طور گسترده در ارائه ستون فقرات برای تضمین امنیت بیشتر و حفظ حریم خصوصی در زمینه های مختلف، از جمله اکوسیستم اینترنت اشیا<sup>۴</sup> بسیار مهم است. بلاکچین عمدتاً یک دفتر دیجیتالی از تراکنش ها است که در کل شبکه سیستم های رایانه ای روی بلاک چین توزیع می شود. مطالعات نشان می دهند که بیت کوین و ارزهای ملی انتقال شوک نوسانات را نشان می دهند، در حالی که عدم قطعیت سیاست اقتصادی تأثیر کمی دارد. یکی از جذاب ترین بازارها برای سفته بازی های مالی، بازار ارزهای دیجیتال است، به این معنی که فعالیت های فریبنده از طریق رسانه های اجتماعی رونق گرفته است. بسیاری از مردم از طریق سفته بازی در بازارهای دیجیتال سود زیادی به دست آورده اند، اما هر فرآیند سرمایه گذاری از ریسک های پنهان زیادی رنج می برد و برخی از سرمایه گذاران، به ویژه آن هایی که تحمل ریسک بالایی دارند، علاقه مند به سرمایه گذاری در ارزهای دیجیتال هستند [۲، ۴].

## مبانی نظری

## یادگیری ماشین

یادگیری ماشین یکی از زیرمجموعه های هوش مصنوعی است که به سیستم ها این امکان را می دهد تا به صورت خودکار یادگیری و پیشرفت داشته باشند بدون اینکه به برنامه نویسی صریحی برای آن داشته باشند. تمرکز اصلی یادگیری ماشینی بر توسعه برنامه های رایانه ای است که بتوانند به داده ها دسترسی پیدا کنند و از آن برای یادگیری خود استفاده کنند. فرآیند یادگیری با مشاهدات یا داده ها آغاز می شود، مانند مثال ها، تجارب مستقیم و یا دستورالعمل ها، تا به یک الگو در داده ها برسند و بر اساس این مثال هایی که ارائه می دهیم، تصمیمات بهتری بگیرند. هدف اصلی آن است که به کامپیوتر این اجازه را بدهیم که بدون دخالت و کمک انسان به طور اتوماتیک یادگیری داشته باشند و بتوانند اقدامات خود را بر مطابق با آن تنظیم کنند [۸].

## یادگیری عمیق

یادگیری عمیق که در زبان فارسی به یادگیری ژرف نیز ترجمه شده است، یک زیر شاخه از یادگیری ماشین و بر مبنای مجموعه ای از الگوریتم ها است که در تلاش اند تا مفاهیم انتزاعی سطح بالا در دادگان را مدل نمایند که این فرایند را با استفاده از یک گراف عمیق که دارای چندین لایه پردازشی متشکل از چندین لایه تبدیلات خطی و غیرخطی هستند، مدل می کنند. به بیان دیگر پایه آن بر یادگیری نمایش دانش و ویژگی ها در لایه های مدل است. یادگیری عمیق، ردهای از الگوریتم های یادگیری ماشین است که از چندین لایه برای استخراج ویژگی های سطح بالا از ورودی خام استفاده می کنند. به بیانی دیگر، ردهای از تکنیک های یادگیری ماشین که از چندین لایه پردازش اطلاعات و به ویژه اطلاعات غیرخطی بهره می برد

<sup>1</sup> Bitcoin<sup>2</sup> Cryptocurrency<sup>3</sup> Blockchain<sup>4</sup> Internet of Things (IoT)

تا عملیات تبدیل یا استخراج ویژگی نظارت شده یا نظارت نشده را عموماً با هدف تحلیل یا بازشناخت الگو، کلاس بندی، خوشه بندی انجام دهد [۱۴].

### ارز دیجیتال

ارزدیجیتال (همچنین به عنوان رمزارز شناخته می شود) یک ارز دیجیتال است که برای کار به عنوان یک وسیله مبادله طراحی شده است. از رمزنگاری برای ایمن سازی و تأیید تراکنش ها و همچنین کنترل ایجاد واحدهای جدید یک ارز دیجیتال خاص استفاده می کند. بسیاری از ارزهای دیجیتال بر اساس فناوری بلاک چین ساخته شده اند، که یک دفتر کل توزیع شده است که توسط یک شبکه توزیع شده از رایانه ها اجرا می شود. ارزهای دیجیتال از ارزهای فیات مانند دلار ایالات متحده یا پوند انگلیس متمایز می شوند زیرا هیچ مرجع مرکزی آنها را صادر نمی کند و به طور بالقوه آنها را در برابر مداخله یا دستکاری دولت غیرقابل نفوذ می کند. این بخش مفاهیم مختلف ارز دیجیتال را مورد بحث قرار می دهد [۲۴].

### مزایا و معایب ارزهای دیجیتال

تراکنش ارز دیجیتال معمولاً یک فرآیند سریع و ساده است. به عنوان مثال، بیت کوین را می توان بین کیف پول های دیجیتال تنها با استفاده از یک گوشی هوشمند یا رایانه مبادله کرد. کلیدهای عمومی و خصوصی و طرح های تشویقی مختلف مانند اثبات کار و اثبات سهام برای محافظت از این نقل و انتقالات استفاده می شود. پرداخت با ارزهای رمزنگاری شده در بین شرکت های بزرگ و در صنایعی مانند مد و داروسازی محبوبیت بیشتری پیدا می کند. هر تراکنش ارز دیجیتال در یک دفتر کل به نام بلاک چین ثبت می شود، که فناوری است که وجود آن را ممکن می کند. این به افراد اجازه می دهد تا تاریخچه ارزهای رمزنگاری شده مانند بیت کوین را دنبال کنند تا از خرج کردن سکه هایی که مالک آن نیستند، کپی کردن تراکنش ها یا لغو آنها جلوگیری کنند [۲۶]. از آنجایی که بلاک چین قصد دارد واسطه هایی مانند بانک ها و بازارهای اینترنتی را حذف کند، هیچ هزینه تراکنشی وجود ندارد. با این حال، احتمالاً کیف پول مجازی خود را در جای خود قرار نمی دهید یا سکه های خود را از دست خواهید داد. همچنین سرقت هایی از وب سایت هایی که برای ذخیره ارزهای دیجیتال در اینترنت وجود دارند، صورت گرفته است. از آنجایی که ارزش ارزهای رمزنگاری شده مانند بیت کوین می تواند به شدت در نوسان باشد، برخی افراد در تبدیل پول واقعی به بیت کوین تردید دارند.

### مروری بر پیشینه پژوهش

ارزهای دیجیتال در سال های اخیر رشد چشمگیری داشته است. رویدادهای اضافی در سراسر سیاره اهمیت استقبال از مزایای عددی را با پیشرفت های سریعی که در این جهت ها مشاهده می شود، تصدیق کرده اند. در بازار مالی امروزی، تصمیم برای خرید یا فروش ارز دیجیتال چالش جالبی است که معامله گران روزانه با آن مواجه هستند. در طول سال، به اوج های بی سابقه ای رسیده است که منجر به افکاری شده است که روند رشد آن را توضیح می دهد. این ایده که آیا می توان حرکت دارایی های مالی را پیش بینی کرد یا خیر، سرمایه گذاران، اقتصاددانان و محققان را در سال های اخیر بسیار درگیر کرده است. بنابراین، مقاله [۲۸] از یادگیری ماشین برای ساخت مدلی برای پیش بینی قیمت سهام و ارز دیجیتال با استفاده از شاخص های فنی که برای مطالعه روند بازار مهم هستند، استفاده کرد. این مقاله یاد می گیرد که چگونه حافظه طولانی کوتاه مدت را برای ساخت مدل پیش بینی قیمت ارزهای دیجیتال تطبیق دهد. عوامل کلیدی مورد استفاده عبارتند از قیمت در دسترس، قیمت بسته، قیمت بالا، قیمت پایین، حجم و ارزش بازار با وابستگی های متقابل در میان برخی ارزهای دیجیتال، بنابراین بر اندازه گیری ویژگی های حیاتی متمرکز است که با اعمال مدل برای افزایش اثربخشی فرآیند، غیرقابل پیش بینی بودن معامله را تحت تأثیر قرار می دهد. با این وجود، بازار ارزهای دیجیتال فاقد ساختارهای نظارتی محکم و غیرقابل پیش بینی است و پیش بینی قیمت ها را دشوارتر و پیچیده تر می کند. از تجزیه و تحلیل، مشخص شد که مدل های یادگیری ماشین عملکرد بهتری در پیش بینی قیمت ارزهای دیجیتال ارائه می کنند. مدل LSTM از نظر ارزهای دیجیتال بیت کوین، اتر و لایت کوین از سایر مدل ها بهتر عمل کرد. مدل پیشنهادی در مقایسه با مدل های مشابه با دقت ۶۷،۴۳ درصد برای پیش بینی قیمت ارزهای دیجیتال کارآمد است.

طی تحولات اخیر، ارزش دیجیتال به یک عامل کلیدی معروف در فرصت‌های مالی و تجاری تبدیل شده است. با این حال، سرمایه‌گذاری در ارزش‌های دیجیتال با توجه به جنبه ناسازگار بازار و نوسان قیمت‌های بالا قابل مشاهده نیست. با توجه به پیش‌بینی لحظه‌ای قیمت‌ها، رویکردهای قبلی در پیش‌بینی قیمت حاوی اطلاعات و راه‌حل کافی برای پیش‌بینی تغییرات قیمت نیستند. بر اساس مشکلات ذکر شده در پیش‌بینی قیمت ارزش‌های دیجیتال، پژوهش [۲۹] یک رویکرد مبتنی بر یادگیری ماشین را برای پیش‌بینی قیمت برای یک موسسه مالی پیشنهاد کرده است. سیستم پیشنهادی شامل چارچوب بلاک چین برای محیط تراکنش امن و الگوریتم یادگیری تقویتی<sup>۵</sup> برای تحلیل و پیش‌بینی قیمت است. تمرکز اصلی این سیستم بر روی ارزش‌های دیجیتال لایت کوین و مونرو است. نتایج نشان داده که سیستم ارائه‌شده عملکرد پیش‌بینی قیمت را بالاتر از الگوریتم پیشرفته دیگری است.

اخیراً فناوری‌های بلاک چین مبتنی بر بیت‌کوین مورد توجه سرمایه‌گذاران قرار گرفته است. آنها بر پیش‌بینی نرخ بازده و ریسک محصول مالی تمرکز کرده‌اند. بنابراین، یک ابزار خودکار برای پیش‌بینی نرخ بازگشت بیت کوین برای محصولات مالی مورد نیاز است. مدل‌های یادگیری ماشین و یادگیری عمیق که اخیراً طراحی شده‌اند، راه را برای فرآیند پیش‌بینی نرخ بازگشت هموار می‌کنند. در این جنبه، مطالعه [۳۰] یک رویکرد پیش‌بینی نرخ بازگشت هوشمند با استفاده از یادگیری عمیق برای محصولات مالی بلاک چین ایجاد کرده است. روش پیشنهادی شامل طراحی یک مدل حافظه طولانی کوتاه‌مدت برای تحلیل پیش‌بینی نرخ بازگشت است. علاوه بر این، بهینه‌ساز Adam برای تنظیم بهینه فرآیندهای مدل LSTM و در نتیجه افزایش عملکرد پیش‌بینی اعمال شده است. نرخ یادگیری مدل LSTM با استفاده از الگوریتم بهینه‌سازی ازدحام کرم درخشانده مخالف<sup>۶</sup> تنظیم شده است. طراحی الگوریتم OGSO برای بهینه‌سازی هاپرپارامترهای LSTM برای پیش‌بینی نرخ بازگشت بیت کوین، تازگی کار را نشان می‌دهد. برای اطمینان از عملکرد عالی تکنیک پیشنهادی، نرخ بازگشت اتریوم به عنوان هدف انتخاب شده و نتایج شبیه‌سازی در معیارهای مختلف بررسی شده‌اند. نتایج شبیه‌سازی برتری تکنیک پیشنهادی مطالعه را بر تکنیک‌های فعلی از نظر پارامترهای ارزیابی متنوع برجسته کرده است.

ارزهای مجازی به عنوان یکی از دارایی‌های مالی که به‌طور گسترده به عنوان ارزش مبادله‌ای شناخته می‌شود، اعلام شده است. معاملات ارزش‌های دیجیتال توجه سرمایه‌گذاران را به خود جلب کرد زیرا ارزش‌های دیجیتال می‌توانند به عنوان سرمایه‌گذاری‌های بسیار سودآور در نظر گرفته شوند. برای بهینه‌سازی سود سرمایه‌گذاری در ارزش‌های دیجیتال، پیش‌بینی دقیق قیمت ضروری است. با توجه به این واقعیت که پیش‌بینی قیمت یک کار سری زمانی است، در مقاله [۳۱] یک مدل یادگیری عمیق ترکیبی برای پیش‌بینی قیمت آتی ارزش دیجیتال پیشنهاد شده است. مدل ترکیبی یک شبکه عصبی پیچشی<sup>۷</sup> یک بعدی و واحد بازگشتی دروازه‌ای پشته‌ای<sup>۸</sup> را ادغام کرده است. با توجه به داده‌های قیمت ارزش‌های دیجیتال در طول زمان، شبکه عصبی کانولوشنیک یک بعدی داده‌ها را در یک نمایش تبعیض‌آمیز سطح بالا رمزگذاری می‌کند. متعاقباً، واحد بازگشتی دروازه‌ای انباشته، وابستگی‌های دوربرد نمایش را به تصویر می‌کشد. مدل ترکیبی پیشنهادی بر روی سه مجموعه داده ارزش‌های دیجیتال مختلف، یعنی بیت کوین، اتریوم و ریپل مورد ارزیابی قرار گرفته است. نتایج تجربی نشان داده که مدل پیشنهادی مقاله از روش‌های موجود، کمترین مقادیر خطا را در مجموعه داده بیت‌کوین، اتریوم و ریپل داشته است.

## روش تحقیق

### الگوریتم واحد برگشتی دروازه‌دار

با توجه به اینکه، الگوریتم واحد برگشتی دروازه‌دار نسخه بهبود یافته شبکه عصبی بازگشتی استاندارد هستند. برای حل مشکل گرادینان ناپدید شدن یک شبکه عصبی بازگشتی استاندارد، الگوریتم واحد برگشتی دروازه‌دار از گیت بروزرسانی و گیت ریست استفاده می‌کند. اساساً، این دو بردار هستند که تصمیم می‌گیرند چه اطلاعاتی باید به خروجی ارسال شود. نکته ویژه


<sup>۵</sup> Reinforcement Learning (RL)

<sup>۶</sup> Oppositional Glowworm Swarm Optimization (OGSO)

<sup>۷</sup> convolutional neural network (CNN)

<sup>۸</sup> stacked gated recurrent unit (SGRU)

در مورد آنها این است که می توان آنها را آموزش داد تا اطلاعات را از مدت ها قبل بدون شستن آن در طول زمان یا حذف اطلاعاتی که به پیش بینی بی ربط است، نگه دارند. برای توضیح معادلات پشت آن فرآیند، شکل ۱ یک نسخه دقیق از GRU واحد را ارائه نموده است.



شکل ۱ - نمونه ای از واحد برگشتی دروازه دار

- **گیت بروزرسانی:** با محاسبه گیت بروزرسانی  $z_t$  برای مرحله زمانی  $t$  با استفاده از فرمول ۱ شروع می شود. هنگامی که  $x_t$  به واحد شبکه متصل می شود، در وزن خودش  $W^{(z)}$  ضرب می شود. همین امر در مورد  $h_{t-1}$  نیز صدق می کند که اطلاعات واحدهای  $t-1$  قبلی را نگه می دارد و در وزن خودش  $U^{(z)}$  ضرب می شود. هر دو نتیجه با هم جمع می شوند و یک تابع فعال سازی سیگموید برای له کردن نتیجه بین ۰ و ۱ اعمال می شود. گیت بروزرسانی به مدل کمک می کند تا تعیین کند چه مقدار از اطلاعات گذشته (از مراحل زمانی قبلی) باید به آینده منتقل شود. این واقعاً قدرتمند است زیرا مدل می تواند تصمیم بگیرد که تمام اطلاعات گذشته را کپی کند و خطر ناپدید شدن مشکل گرادیان را از بین ببرد.

$$z_t = \sigma(W^{(z)}x_t + U^{(z)}h_{t-1}) \quad ۱$$

- **گیت بازنشانی:** اساساً، این گیت از مدل استفاده می شود تا تصمیم بگیرد چه مقدار از اطلاعات گذشته را فراموش نماید که برای محاسبه آن از فرمول ۲ استفاده می شود. این فرمول مانند فرمول گیت بروزرسانی است. تفاوت در وزن ها و استفاده از دروازه است که در مدتی مشخص خواهد شد. مانند قبل،  $x_t$  و  $h_{t-1}$  وصل می شود، و آنها با وزن های مربوطه ضرب می شوند، نتایج را جمع نموده و تابع سیگموید اعمال می گردد.

$$r_t = \sigma(W^{(r)}x_t + U^{(r)}h_{t-1}) \quad ۲$$

- **محتوای حافظه فعلی:** ابتدا با استفاده از گیت ریست شروع می کنیم. ما یک محتوای حافظه جدید را معرفی نموده که از دروازه تنظیم مجدد برای ذخیره اطلاعات مربوطه از گذشته استفاده می کند. به صورت زیر محاسبه می شود:

○ ورودی  $x_t$  با وزن  $W$  و  $h_{t-1}$  با وزن  $U$  ضرب می شود.

○ حاصل ضرب هادامارد (بر حسب عنصر) بین گیت تنظیم مجدد  $r_t$  و  $h_{t-1}$   $U^{(r)}$  محاسبه می شود که مشخص می کند چه چیزی از مراحل قبلی حذف شود.

○ نتایج مرحله ۱ و ۲ جمع بندی خواهد شد.

○ تابع فعال سازی غیرخطی  $\tanh$  اعمال می‌شود.

● **حافظه نهایی در مرحله زمانی فعلی:** به عنوان آخرین مرحله، شبکه باید  $h_t$  محاسبه می‌شود که اطلاعات واحد فعلی را نگه می‌دارد و آن را به شبکه ارسال می‌کند. برای انجام این کار به گیت بروزرسانی نیاز است. تعیین می‌کند که چه چیزی از محتوای حافظه فعلی  $h_t$  و چه چیزی از مراحل قبلی  $h_{t-1}$  جمع آوری شود. که به صورت زیر انجام می‌شود:

○ ضرب عنصر در گیت بروزرسانی  $z_t$  و  $h_{t-1}$  اعمال می‌شود.

○ ضرب عنصر در  $(z_{t-1})$  و  $h_{th'}_t$  اعمال می‌گردد.

○ نتایج مرحله ۱ و ۲ جمع آوری خواهد شد.

اکنون، می‌توان عنوان کرد که چگونه GRUها می‌توانند اطلاعات را با استفاده از گیت های بروزرسانی و تنظیم مجدد خود ذخیره و فیلتر کنند. این مشکل گرادیان ناپدید شدن را از بین می‌برد زیرا مدل هر بار ورودی جدید را پاک نمی‌کند، بلکه اطلاعات مربوطه را نگه می‌دارد و آن را به مراحل زمانی بعدی شبکه منتقل می‌کند. اگر به دقت آموزش داده شوند، حتی در سناریوهای پیچیده نیز می‌توانند بسیار خوب عمل کنند.

### الگوریتم حافظه کوتاه مدت طولانی


الگوریتم حافظه کوتاه مدت طولانی یک مدل شبکه است که برای حل مشکلات طولانی مدت انفجار گرادیان و ناپدید شدن گرادیان در شبکه عصبی بازگشتی طراحی شده است. این الگوریتم به طور گسترده ای در تشخیص گفتار، تجزیه و تحلیل عاطفی و تحلیل متن استفاده شده است، زیرا حافظه خاص خود را دارد و می‌تواند پیش‌بینی نسبتاً دقیقی را انجام دهد. در سال های اخیر، در زمینه پیش‌بینی بازار سهام نیز مورد استفاده قرار گرفته است. تنها یک ماژول تکراری در یک شبکه عصبی بازگشتی استاندارد وجود دارد و ساختار داخلی آن ساده است. معمولاً یک لایه  $\tanh$  است. با این حال، چهار مورد از ماژول های LSTM مشابه ماژول های استاندارد شبکه عصبی بازگشتی هستند و به شیوه ای تعاملی خاص عمل می‌کنند. سلول حافظه LSTM از سه بخش دروازه فراموشی، دروازه ورودی و دروازه خروجی تشکیل شده است که در شکل نشان داده شده است.

فرآیند محاسبه LSTM به شرح زیر است:

(۱) مقدار خروجی لحظه آخر و مقدار ورودی زمان جاری به دروازه فراموشی وارد می‌شود و مقدار خروجی دروازه فراموشی پس از محاسبه بدست می‌آید، همانطور که در فرمول ۳ نشان داده شده است:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad 3$$

که در آن محدوده مقدار  $f_t$  در بازه (۰، ۱) است،  $W_f$  وزن دروازه فراموشی است، و  $b_f$  بایاس دروازه فراموشی،  $x_t$  مقدار ورودی زمان جاری و  $h_{t-1}$  مقدار خروجی آخرین لحظه است.



شکل ۲- معماری سلول حافظه LSTM

(۲) مقدار خروجی آخرین زمان و مقدار ورودی زمان جاری در دروازه ورودی وارد می‌شود و مقدار خروجی و وضعیت سلول کاندید دروازه ورودی پس از محاسبه بدست می‌آید، همانطور که در فرمول‌های ۴ و ۵ نشان داده شده است:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\bar{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

که در آن محدوده مقدار  $i_t$  در بازه (۰، ۱) است،  $W_i$  وزن دروازه ورودی است، و  $b_i$  بایاس دروازه ورودی،  $W_c$  وزن دروازه ورودی نامزد است و  $b_c$  بایاس دروازه ورودی نامزد است.

(۳) وضعیت سلول فعلی را به صورت ۶ به روز می‌شود:

$$C_t = f_t \times C_{t-1} + i_t \times \bar{C}_t \quad (6)$$

در معادله فوق محدوده مقدار  $C_t$  در بازه (۰، ۱) است.

(۴) خروجی  $h_{t-1}$  و ورودی  $x_t$  به عنوان مقادیر ورودی دروازه خروجی در زمان  $t$  دریافت می‌شود و  $o_t$  خروجی دروازه خروجی به صورت ۷ به دست می‌آید:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad 7$$

که در آن مقدار  $o_t$  در بازه (۰، ۱) است،  $W_o$  وزن دروازه خروجی است، و  $b_o$  بایاس دروازه خروجی است.

(۵) مقدار خروجی LSTM با محاسبه خروجی، دروازه خروجی و وضعیت سلول به دست می آید که در فرمول ۸ نشان داده شده است.

$$h_t = o_t \times \tanh(C_t) \quad 8$$

شکل شبه کد اجرای الگوریتم LSTM را برای دستیابی به یک روش مناسب جهت پیش‌بینی قیمت ارزهای دیجیتال را نشان می‌دهد. همانطور که در این الگوریتم نشان داده شده است، ابتدا مجموعه داده مورد نظر برای پیش‌بینی قیمت ارزهای دیجیتال وارد می‌شود و سپس مجموعه داده به دو بخش آموزشی (۷۵ درصد مجموعه داده) و آزمایشی (۲۵ درصد مجموعه داده) تقسیم خواهد شد. پس از تقسیم بندی داده‌ها، نوبت به انجام فرآیند الگوریتم LSTM خواهد رسید که در آن ابتدا فرآیند ایجاد لایه‌های مختلف انجام خواهد شد و سپس با بررسی میزان کارایی لایه‌های ایجاد شده و رضایت بخشی آنها، فرآیند پیش‌بینی قیمت ارزهای دیجیتال براساس ویژگی‌های استخراج شده انجام خواهد شد.

```
# LSTM
• Inputs: dataset
• Outputs: Parameters Of Testing
.
• # Split dataset into 75% training and 25% testing data
• size = length(dataset) * 0.75
• train = dataset [0 to size]
• test = dataset [size to length(dataset)]
.
• # Procedure to fit the LSTM model
• Procedure LSTMAlgorithm (train, test, train_size, epochs)
• X = train
• y = test
• model = Sequential ()
• model.add(LSTM(50), stateful=True)
• model.compile(optimizer='adam', loss='mse')
• model.fit(X, y, epochs=epochs, validation_split=0.2)
• return model
.
• # Procedure to make predictions
• Procedure getPredictionsFromModel (model, X)
• predictions = model.predict(X)
• return predictions
.
• epochs = 100
• neurons = 50
• predictions = empty
# Fit the LSTM model
• model = LSTMAlgorithm (train, epoch, neurons)
.
• # Make predictions
• pred = model.predict(train)
.
• # Validate the model
• n = len(dataset)
```


### شبه کد الگوریتم LSTM

### فرآیند آموزش و پیش‌بینی GRU-LSTM

فرآیند آموزش و پیش‌بینی الگوریتم مورد هدف این پژوهش در شکل نشان داده شده است. مراحل اصلی به شرح زیر است:

(۱) داده ورودی: داده‌های مورد نیاز برای آموزش GRU-LSTM وارد می‌شود.

(۲) **استانداردسازی داده‌ها:** از آنجایی که شکاف زیادی در داده‌های ورودی وجود دارد، به منظور آموزش بهتر مدل، روش استانداردسازی Z-score برای استانداردسازی داده‌های ورودی اتخاذ می‌شود، همانطور که در فرمول ۹ و ۱۰ نشان داده شده است.



شکل ۳- نمودار فعالیت GRU-LSTM آموزش و فرآیند پیش‌بینی

۹

$$y_i = (x_i - \bar{x}) / s$$

۱۰

$$\bar{x}_i = y_i \times s + \bar{x}$$

در معادلات فوق  $y_i$  مقدار استاندارد شده،  $x_i$  داده ورودی،  $\bar{x}$  میانگین داده‌های ورودی و  $s$  انحراف استاندارد داده‌های ورودی است.

(۳) **راه‌اندازی شبکه:** وزن‌ها و بایاس‌های هر لایه از GRU-LSTM مقداردهی می‌شود.

(۴) **محاسبه گیت GRU:** داده‌های ورودی به‌طور متوالی از گیت‌های بروزرسانی، بازنشانی و حافظه نهایی در روش GRU عبور می‌کنند، استخراج ویژگی داده‌های ورودی انجام می‌شود و مقدار خروجی به دست می‌آید.

(۵) **محاسبه لایه LSTM:** داده‌های خروجی الگوریتم GRU از طریق لایه LSTM محاسبه می‌شود و مقدار خروجی به دست می‌آید.

(۶) **محاسبه لایه خروجی:** مقدار خروجی لایه LSTM به لایه اتصال کامل وارد می‌شود تا مقدار خروجی بدست آید.

(۷) **خطای محاسبه:** مقدار خروجی محاسبه شده توسط لایه خروجی با مقدار واقعی این گروه از داده‌ها مقایسه شده و خطای مربوطه به دست می‌آید.

(۸) **برای قضاوت در مورد اینکه آیا شرط پایان برآورده شده است:** شرایط پایان عبارت است از تکمیل تعداد چرخه های از پیش تعیین شده، وزن کمتر از یک آستانه معین و میزان خطای پیش‌بینی کمتر از یک آستانه خاص است. در صورت تحقق یکی از شرایط پایان، آموزش تکمیل می‌شود، کل شبکه GRU-LSTM بروز می‌شود و به مرحله ۱۰ می‌رود. در غیر این صورت به مرحله ۹ می‌رود.

(۹) **پس انتشار خطا:** خطای محاسبه شده را در جهت مخالف منتشر کنید، وزن و بایاس هر لایه بروز می‌شود و برای ادامه آموزش شبکه به مرحله ۴ می‌رود.

(۱۰) **ذخیره مدل:** مدل آموزش دیده برای پیش‌بینی ذخیره می‌شود.

(۱۱) **داده ورودی:** داده‌های ورودی مورد نیاز برای پیش‌بینی وارد می‌شود.


(۱۲) **استانداردسازی داده‌ها:** داده‌های ورودی طبق فرمول ۳-۹ استاندارد می‌شوند.

(۱۳) **پیش‌بینی:** داده‌های استاندارد شده در مدل آموزش دیده GRU-LSTM وارد می‌شود و سپس مقدار خروجی مربوطه دریافت خواهد شد.

(۱۴) **بازیابی استاندارد داده شده:** مقدار خروجی بدست آمده از طریق مدل GRU-LSTM مقدار استاندارد شده است و مقدار استاندارد شده به مقدار اولیه بازیابی می‌شود. همانطور که در فرمول ۳-۱۰ نشان داده شده است که در آن  $x_i$  مقدار بازیابی شده استاندارد شده،  $y_i$  مقدار خروجی GRU-LSTM،  $s$  انحراف استاندارد داده‌های ورودی و  $\bar{x}$  مقدار متوسط داده‌های ورودی است.

(۱۵) **نتیجه خروجی:** خروجی نتایج بازیابی شده برای تکمیل فرآیند پیش‌بینی.

نتایج روش پیشنهادی



شکل ۴

الگوریتم پیشنهادی مبتنی بر الگوریتم حافظه طولانی کوتاه مدت و واحد بازگشتی دروازه‌ای برای پیش‌بینی نمونه های آزمون دوره ۱ و دوره ۲ استفاده می‌شود و نتایج نشان داده شده در جدول و شکل زیر به دست آمده است. خط قرمز قیمت بیت کوین و خط چین سبز قیمتی است که توسط روش پیشنهادی برای پیش‌بینی بدست آمده است.

#### جدول ۱- قیمت پیش‌بینی شده بر اساس الگوریتم پیشنهادی و مقایسه قیمت واقعی

##### نتایج خطا برای الگوریتم پیشنهادی


| دوره ۲  | دوره ۱ |                                       |
|---------|--------|---------------------------------------|
| ۲۰۹۶,۲۴ | ۳۲۱,۶۱ | مجذور میانگین مربعات خطا <sup>۹</sup> |
| ٪۳,۳۹   | ٪۳,۳۹  | میانگین درصد خطای مطلق <sup>۱۰</sup>  |

اگرچه RMSE دوره ۱ بسیار کوچکتر از دوره ۲ است، از آنجایی که میانگین قیمت بیت کوین در دوره ۱ نیز بسیار کمتر از دوره ۲ است، مقایسه نتایج RMSE دوره های مختلف بی معنی است. شاخص MAPE در دو دوره کاملاً نزدیک هستند و دقت پیش‌بینی دوره ۲ کمی بهتر از دوره ۱ است. شایان ذکر است که در مرحله اولیه بازه آزمایشی دوره ۲، الگوریتم پیشنهادی زمانی که قیمت بیت کوین بیشتر از ۶۰۰۰۰ دلار آمریکا باشد پیش‌بینی بدی دارد زیرا نمونه های بسیار کمی با قیمت بیت کوین بیشتر از ۶۰۰۰۰ دلار در نمونه های آموزشی دوره ۲ وجود دارد. این نتیجه به‌طور دقیق ناتوانی الگوریتم پیشنهادی مبتنی بر حافظه طولانی کوتاه مدت و واحد بازگشتی دروازه‌ای را نشان می‌دهد. با این حال، چه دوره ۱ باشد و چه دوره ۲، روش پیشنهادی عملکرد عالی را در پیش‌بینی قیمت های زیر ۶۰۰۰۰ دلار نشان می‌دهد و روند قیمت پیش‌بینی شده با روند قیمت واقعی مطابقت دارد.

علاوه بر تحلیل پیش‌بینی کننده، الگوریتم مبتنی بر حافظه طولانی کوتاه مدت و واحد بازگشتی دروازه ای نیز اهمیت هر متغیر توضیحی را هنگام پیش‌بینی قیمت بیت کوین، از طریق آمار تعداد وقوع متغیرهای مرزی ارائه می‌کند. نتیجه در شکل نشان داده شده است.


<sup>۹</sup> Root Mean Square Error (RMSE)

<sup>۱۰</sup> Mean Absolute Percentage Error (MAPE)




شکل ۵- رتبه بندی متغیرهای توضیحی با استفاده از روش پیشنهادی

افزایش قابل توجه RMSE در دوره ۱ زمانی رخ می‌دهد که متغیر یا ویژگی قیمت بازگشایی بیت کوین در حالت روزانه (BTC\_Open) حذف شود. حذف BTC\_Open مربوط به حذف آن از داده‌های روز قبل است، که نشان می‌دهد هنگام پیش‌بینی قیمت بیت کوین بعدی، حداقل یکی از قیمت بیت کوین فعلی مورد نیاز است. در دوره ۲، سه تغییر بزرگ در RMSE زمانی رخ داد که مقدار بازگشایی قیمت بیت کوین، قیمت اتریوم و دوج کوین به‌طور جداگانه حذف شدند. اگرچه نتیجه روش پیشنهادی مبتنی بر الگوریتم‌های یادگیری عمیق حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه ای نشان می‌دهد که دوج کوین کمتر از JP225 و S&P500 در تعیین نتایج ظاهر می‌شود، افزایش شدید RMSE پس از حذف دوج کوین اثر آن را بر دقت پیش‌بینی نشان می‌دهد. سه تغییر بزرگ در دوره ۲ همگی مربوط به متغیرهای قیمت ارزهای دیجیتال است که نشان می‌دهد همبستگی بین قیمت بیت کوین و بازار ارزهای دیجیتال پس از سال ۲۰۱۸ افزایش یافته است. پیش‌بینی عملکرد بین مدل با همه متغیرها و مدل فقط با متغیرهای مهم شامل قیمت پایان روز بیت کوین، بیشترین قیمت روزانه بیت کوین، پایین‌ترین قیمت روزانه بیت کوین برای دوره ۱ و قیمت بسته شده بیت کوین به‌صورت روزانه، کمترین و بیشترین قیمت روزانه بیت کوین، قیمت روزانه اتریوم و ریپل برای دوره ۲ نتایج نشان می‌دهد که دقت پیش‌بینی مدل با همه متغیرهای توضیحی بهتر است در حالی که مقدار RMSE حدود ۳ درصد کمتر از نتایج تنها با استفاده از متغیرهای مهم است که در شکل نشان داده شده است.



شکل ۶- مقایسه پیش‌بینی قیمت بیت کوین با همه متغیرها و متغیرهای مهم

با توجه به نتایج بدست آمده در بخش های قبل، می توان دریافت که آوردن متغیرهای توضیحی اضافی به مدل برای آموزش منجر به کاهش دقت مدل می‌شود. دقت مدلی که پس از وارد کردن همه ۴۷ متغیر توضیحی به دست می‌آید، کمتر از مدلی است که بخشی از متغیرها را استفاده می‌کند، مانند مدلی که نشان داده شده که تنها از چهار متغیر قیمت بیت‌کوین استفاده می‌کند. در مقابل، اگر از متغیرهای توضیحی خیلی کم استفاده شود، دقت پیش‌بینی مدل نیز کاهش می‌یابد. به عنوان مثال، پس از افزودن چند متغیر دیگر به مدل قبلی با چهار متغیر قیمت بیت کوین، دقت پیش‌بینی مدل بهتر می‌شود. بنابراین، این پژوهش آزمایش‌ها و تلاش‌های زیادی انجام داده که در هر دوره چه مجموعه‌ای از متغیرهای توضیحی باید جایگزین شوند. از آنجایی که در روش پیشنهادی مبتنی بر یادگیری عمیق به دلیل الگوریتم مجموعه بودن چنین مشکلی وجود ندارد. از آنجایی که ترکیب متغیرهای توضیحی وارد شده مستقیماً بر دقت پیش‌بینی مدل تأثیر می‌گذارد، با اشاره به رتبه اهمیت متغیرهای توضیحی با استفاده از روش پیشنهادی، مجموعه متغیرهای توضیحی مربوطه دوره ۱ و دوره ۲ در جدول تنظیم شده‌اند. از آنجایی که نتایج یادگیری عمیق با ترکیب نمونه های یادگیری به‌طور تصادفی انتخاب شده از نمونه مرتبط است، تصادفی بودن در نتایج تجربی وجود دارد. بنابراین، هنگام مقایسه نتایج مدل، به جای مقایسه دقت یک مدل، میانگین نتایج ۳۰ آزمایش برای مدل‌های مختلف مقایسه می‌شود. روش مقایسه میانگین نتایج تجربی چندگانه نیز در آزمایشات انجام شده توسط بسیاری از مطالعات به کار گرفته شده است. دقت مدل‌ها برای دو دوره در شکل نشان داده شده است.




شکل ۷- مقایسه پیش‌بینی قیمت بیت کوین با همه متغیرها و متغیرهای مهم

هنگامی که قیمت بیت کوین در دوره اولیه دوره ۲ از ۶۰۰۰۰ دلار بیشتر است، نتایج پیش‌بینی الگوریتم پیشنهادی با همان مشکل کم‌سنجی مواجه شد که در حالت‌های با یک تکرار فرآیند پیش‌بینی انجام شده است. با مقایسه MAPE دو دوره، دقت پیش‌بینی قیمت بیت کوین در دوره ۱ بهتر از دوره ۲ است. این نشان می‌دهد که همبستگی بین بیت کوین و بازارهای سنتی در سال‌های اخیر کاهش یافته و تصادفی بودن قیمت‌ها افزایش یافته است. این نتیجه همچنین نتیجه‌گیری را منعکس می‌کند که همبستگی قیمت بیشتر توسط قیمت خود دوره قبل تعیین می‌شود، همانطور که در رتبه‌بندی اهمیت در دوره ۲ با یک تکرار این موضوع منعکس شده است.

#### مقایسه مدل‌ها

با توجه به اینکه روش پیشنهادی از الگوریتم‌های ترکیبی یادگیری عمیق مبتنی بر حافظه طولانی کوتاه‌مدت و واحد دروازه ای بازگشتی استفاده نموده است و نتایج بدست آمده در مرحله قبل نشان می‌دهد که روش پیشنهادی دارای کارایی و دقت مناسبی در پیش‌بینی است. از این رو، در این بخش به منظور دستیابی به نتایج دقیق‌تر و مقایسه عملکرد روش پیشنهادی با دیگر روش‌ها سعی شده تا با مدل‌های مختلف که در بخش پیشینه ارائه شده اند مورد ارزیابی قرار گیرد. برای مقایسه مدل‌ها سعی شده تا از روش‌های نزدیک به راهکارها پیشنهادی و مبتنی بر یادگیری عمیق استفاده شود. الگوریتم‌های مورد مقایسه شامل روش حافظه طولانی کوتاه‌مدت-شبکه عصبی بازگشتی (LSTM-RNN) [۳۶]، مدل تجزیه حالت متغیر و حافظه طولانی کوتاه‌مدت (VMD-LSTM) [۴۰]، الگوریتم بهینه‌سازی ازدحام ذرات و مدل خاکستری کسری (Firefly-SVM) [۴۱] استفاده شود. نتایج حاصل از اجرای روش‌های اشاره شده بدو دوره مختلف از مجموعه داده‌ها نشان داده شده است. همانطور که از این شکل مشخص است، روش پیشنهادی نسبت به دیگر روش‌ها توانسته به نتایج نزدیک‌تری برای قیمت واقعی بیت کوین در دو دوره مختلف دست یابد و به نوعی مقادیر پیش‌بینی شده برای روش پیشنهادی با مقادیر واقعی اختلاف کمتری دارند و در مقابل بدترین نتیجه مربوط به الگوریتم ترکیبی بهینه‌سازی ازدحام ذرات و مدل خاکستری کسری است که در بسیاری از بازه‌های زمانی، مقادیر آن با قیمت واقعی بیت کوین اختلاف زیادی دارد و به نوعی میزان انحراف آن از مقدار واقعی بسیاری بیشتر از دیگر الگوریتم‌ها است.



شکل ۸- مقایسه پیش‌بینی قیمت بیت کوین با الگوریتم‌های مختلف

نتیجه‌گیری در مورد تعداد دوره‌های داده مورد نیاز هنگام آموزش مدل‌ها این است که فقط استفاده از آخرین دوره داده کافی است. این نتیجه‌گیری به فرضیه بازار حوزه ارزهای دیجیتال نزدیک است. قیمت فعلی منعکس‌کننده انتظارات بازار از قیمت آتی دارایی است و قیمت دوره قبل ارزش مرجع ندارد. با توجه به جدول خلاصه ۱، می‌توان دریافت که چه دوره ۱ باشد و چه دوره ۲، دقت پیش‌بینی قیمت بیت کوین توسط الگوریتم پیشنهادی مبتنی بر حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای با تأخیر ۱ بهتر از الگوریتم‌های دیگر است.

جدول ۲ - مقایسه الگوریتم‌های مختلف براساس دقت، RMSE و MAPE.

| دوره   | الگوریتم      | دقت    | RMSE          | MAPE  |
|--------|---------------|--------|---------------|-------|
| دوره ۱ | PSO-FGM [41]  | ٪۹۱،۷۶ | ۳۵۸،۶۳(٪۲،۱۲) | ٪۴،۳۷ |
|        | VMD-LSTM [40] | ٪۹۳،۶۱ | ۳۴۷،۵۳(٪۱،۹۲) | ٪۳،۸۷ |
|        | LSTM-RNN [36] | ٪۹۴،۱۱ | ۳۳۰،۲۶(٪۱،۷۱) | ٪۳،۵۷ |
|        | روش پیشنهادی  | ٪۹۷،۸۴ | ۳۲۱،۶۱(٪۱،۶۷) | ٪۳،۳۹ |

|       |                |        |               |        |
|-------|----------------|--------|---------------|--------|
| ۶,۰۸٪ | ۳۱۱۲,۰۹(۳,۴۱٪) | ۹۰,۵۴٪ | PSO-FGM [41]  | دوره ۲ |
| ۴,۹۹٪ | ۳۰۵۷,۴۹(۲,۰۹٪) | ۹۱,۷۷٪ | VMD-LSTM [40] |        |
| ۴,۶۸٪ | ۳۰۴۵,۸۷(۱,۷۱٪) | ۹۲,۳۸٪ | LSTM-RNN [36] |        |
| ۳,۲۹٪ | ۲۰۹۶,۲۴(۳,۴۸٪) | ۹۸,۹۳٪ | روش پیشنهادی  |        |

با توجه به شکل و جدول می توان عنوان کرد که بهترین نتایج و کمترین اختلاف برای پیش بینی قیمت بیت کوین در بازه های زمانی مختلف مربوط به الگوریتم پیشنهادی مبتنی بر ترکیب یادگیری عمیق، حافظه طولانی کوتاه مدت و واحد بازگشتی دروازه ای است که در اجراهای مختلف به میانگین دقت ۹۸,۹۳ درصد دست یافته است که در میان دیگر الگوریتم ها دارای نزدیکترین مقادیر پیش بینی به قیمت واقعی است.

### بحث و نتیجه گیری

از آنجایی که هدف اصلی الگوریتم پیشنهادی پیش بینی قیمت ارزهای دیجیتال در بازارهای رمزارزها است. برای این منظور در این پژوهش از الگوریتم حافظه طولانی کوتاه مدت و واحد بازگشتی دروازه ای و استفاده از برخی ویژگی ها جهت پیش بینی قیمت پیش بینی قیمت ارزهای دیجیتال به خصوص بیت کوین استفاده شده است که در آن با افزودن برخی مراحل به فرآیند پیش پردازش و آموزش سعی شده است تا میزان دقت الگوریتم پیشنهادی افزایش یافته و کارایی آن جهت انجام فرآیند پیش بینی افزایش یابد. در این پژوهش از الگوریتم واحد بازگشتی دروازه ای به منظور استخراج ویژگی های موثر و با اهمیت در پیش بینی قیمت استفاده شده و سپس الگوریتم LSTM برای پیش بینی دقیق و تقویت بیشتر دقت الگوریتم استفاده شده است که به راحتی می تواند در کاربردهای مختلف جهت پیش بینی قیمت مانند قیمت سهام در بازار بورس و غیره استفاده شود. الگوریتم پیشنهادی سعی در استفاده از روشی داشته است که بتواند دقت را در پیش بینی افزایش دهد و از سوی دیگر مقدار پیش بینی را به مقدار واقعی نزدیک نماید به نحوی که اختلاف به کمترین مقدار برسد.

بررسی نتایج بدست آمده نشان داده است که الگوریتم پیشنهادی در فرآیند پیش بینی قیمت ارز دیجیتال بیت کوین کارایی مناسبی دارد و این الگوریتم نیاز به مدت زمان کمتری جهت اجرای فرآیند خود دارد و افزایش تعداد رکوردهای مجموعه داده منجر به افزایش زمان نخواهد شد، در حالیکه انجام این فرآیند در الگوریتم های دیگر طولانی تر است و به نوعی می توان گفت بطور متوسط مدت زمان انجام فرآیند پیش بینی و دستیابی به نتایج بهینه برای مجموعه داده مورد بررسی در الگوریتم پیشنهادی کمتر از الگوریتم های دیگر می باشد. از سوی دیگر، نتایج بدست آمده براساس معیارهای مد نظر پژوهش نشان داده که روش پیشنهادی در مقدار MAPE، RMSE و دقت دارای نتایج بهتری نسبت به دیگر الگوریتم های یادگیری عمیق مانند حافظه طولانی کوتاه مدت- شبکه عصبی بازگشتی، LSTM و مدل تجزیه حالت متغیر، و بهینه سازی ازدحام ذرات و مدل خاکستری کسری دارد و مقادیر بدست آمده برای MAPE و RMSE نشان می دهد که مقدار پیش بینی شده توسط الگوریتم پیشنهادی با مقدار واقعی اختلاف کمتری نسبت به دیگر الگوریتم ها دارد و از سوی دیگر مقدار دقت در روش پیشنهادی به یک نزدیکتر بوده و این نشان می دهد که این الگوریتم در پیش بینی دقت بیشتری داشته است.

فرآیند پیش بینی قیمت ارزهای دیجیتال دارای پیچیدگی ها و پارامترهایی است که نیازمند استفاده از الگوریتم هایی با تعداد فیلترها و شبکه های مختلف است تا این الگوریتم ها بتوانند ویژگی ها و معیارهای تأثیرگذار در قیمت را با دقت و سرعت بیشتری انجام دهند و این موضوع از دیدگاه سرمایه گذاران خرد و کلان به شدت مورد توجه قرار گرفته است و بسیاری از آنها به منظور کسب سود و کاهش ریسک خرید خود در بازار ارزهای دیجیتال به دنبال روش هایی هستند که بتوانند قیمت ارزهای دیجیتال را با دقت بالایی انجام دهند. لذا استفاد از الگوریتم نادرست جهت پیش بینی قیمت منجر به افزایش ریسک سرمایه گذاران و کاهش اطمینان آنها به بازار ارزهای دیجیتال خواهد شد، در نتیجه موضوع پیش بینی قیمت ارزهای دیجیتال برای بسیاری از افراد و شرکت ها اهمیت بالایی خواهد داشت.

در این پژوهش از الگوریتم یادگیری عمیق متشکل از الگوریتم ترکیبی کوتاه‌مدت طولانی و واحد برگشتی دروازه‌دار برای پیش‌بینی قیمت ارزهای دیجیتال به خصوص بیت کوین استفاده گردید. در روش پیشنهادی به منظور کاهش زمان اجرا و افزایش دقت در پیش‌بینی قیمت سعی شده تا فرآیندها با دقت و سرعت مناسبی انجام شوند و با استفاده از فیلترهای مختلف موجود در الگوریتم یادگیری عمیق ارائه شده کارایی افزایش یابد. از این رو، نتایج حاصل از اجرای روش پیشنهادی برای پیش‌بینی قیمت ارزهای دیجیتال نظیر بیت کوین نشان داده که استفاده از راهکار پیشنهادی می‌تواند تا حد زیادی دقت پیش‌بینی را افزایش دهد و مقدار پیش‌بینی را به مقدار واقعی نزدیکتر نماید.

### دستاوردها و یافته‌های پژوهش

با توجه به مطالب ارائه شده می‌توان گفت که در این پژوهش روش مبتنی بر یادگیری عمیق که شامل الگوریتم GRU و LSTM است برای پیش‌بینی قیمت ارزهای دیجیتال مانند بیت کوین استفاده شده است که این راهکار این توانایی را دارد که با دقت بالا و اختلاف کم بین مقدار پیش‌بینی و مقدار واقعی فرآیند را انجام دهد و از سوی دیگر ویژگی‌ها را برای دستیابی به نتیجه مناسب بهینه نماید و نتایج حاصل از ارزیابی روش پیشنهادی برای مجموعه داده ارائه شده با رکوردهای مختلف در دو دوره زمانی متفاوت نشان می‌دهد که روش پیشنهادی کارایی مناسبی برای پیش‌بینی قیمت بیت کوین در بازه های زمانی مختلف دارد. از آنجایی که موضوع پیش‌بینی قیمت ارزهای دیجیتال برای سرمایه‌گذاران خرد و کلان به عنوان یک مسئله مهم و حیاتی است و با روش های سنتی مورد استفاده در یادگیری ماشین متفاوت است، لذا استفاده از الگوریتم پیشنهادی باعث خواهد شد تا دستیابی به نتایج بهینه افزایش یابد.

با توجه به ویژگی‌های زمانی داده‌های قیمت رمزارزها، این پژوهش یک روش ترکیبی مبتنی بر GRU-LSTM را برای پیش‌بینی قیمت ارزهای دیجیتال نظیر بیت کوین پیشنهاد می‌کند. این روش از قیمت بازگشایی روزانه، بالاترین قیمت روزانه، کمترین قیمت روزانه، قیمت بسته شدن روزانه، حجم تراکنش های بیت کوین، فراز و نشیب و تغییر داده‌های مربوط به دیگر ارزهای دیجیتال و حوزه های مالی به عنوان ورودی استفاده می‌کند و از ویژگی های توالی زمانی داده‌ها استفاده کامل می‌کند. در روش پیشنهادی از GRU برای استخراج ویژگی های داده‌های ورودی استفاده می‌شود و الگوریتم LSTM برای یادگیری داده‌های ویژگی استخراج شده و پیش‌بینی قیمت ارزهای دیجیتال استفاده می‌شود. نتایج تجربی نشان می‌دهد که GRU-LSTM بالاترین دقت پیش‌بینی و بهترین عملکرد را در مقایسه با LSTM-RNN، LSTM-VMD و PSO-FGM دارد. MAPE و RMSE کوچکترین مقادیر را دارند و مقدار دقت نزدیک به ۱ است. GRU-LSTM برای پیش‌بینی قیمت ارزهای دیجیتال مناسب است و می‌تواند مرجع مناسبی برای سرمایه‌گذاران برای به حداکثر رساندن بازده سرمایه‌گذاری باشد. GRU-LSTM همچنین پیشنهاد تجربه عملی را برای تحقیقات مردم در مورد داده‌های سری زمانی مالی ارائه می‌دهد.

### پیشنهادهای آینده

برای تحقیقات آینده در این حوزه پیشنهاد می‌شود که آزمایش‌های روش پیشنهادی را بر روی یک سیستم در بازارهای ارز دیجیتال مانند کوین ایکس یا کوین مارکت به صورت بلادرنگ و یا مجموعه داده‌های متفاوت انجام شود تا کارایی راهکار پیشنهادی این پژوهش بطور کامل مورد بررسی قرار گیرد و بتوان از آن در دیگر کاربردها مورد استفاده داد. با توجه به محدودیت هایی که در بخش قبل ارائه گردید و همچنین برخی کمبودها و نواقصی که در راهکار پیشنهادی وجود دارد می‌توان موارد زیر را به عنوان پیشنهاد های آینده پژوهش در نظر گرفت:

- برای مطالعات آینده می‌توان موضوع و مسئله فوق را با پارامترها و معیارهای دیگری ترکیب نمود تا دقت پیش‌بینی افزایش یابد. برای مثال می‌توان عوامل احساسی مانند اخبار و موارد مرتبط با سیاست جهانی را در پیش‌بینی ادغام کند.
- الگوریتم های یادگیری عمیق دیگری را GRU یا LSTM ترکیب کرد و در حال حاضر با توجه به گسترش استفاده از الگوریتم‌های فراابتکاری در کاربردهای مختلف، می‌توان از قابلیت‌های آن برای انجام فرآیند پیش‌بینی قیمت نیز استفاده نمود.

- استفاده از راهکاری که سرعت اجرای آن بیشتر باشد و نیاز به محاسباتی بالایی نداشته باشد و به نوعی با در نظر گرفتن ویژگی های بلادرنگ قیمت ارزهای دیجیتال کارایی بیشتری برای پیش‌بینی قیمت داشته باشد.

## منابع

1. Awoke, Temesgen, Minakhi Rout, Lipika Mohanty, and Suresh Chandra Satapathy. "Bitcoin price prediction and analysis using deep learning models." In Communication Software and Networks: Proceedings of INDIA 2019, pp. 631-640. Singapore: Springer Singapore, 2020.
2. Khedr, Ahmed M., Ifra Arif, Magdi El-Bannany, Saadat M. Alhashmi, and Meenu Sreedharan. "Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey." Intelligent Systems in Accounting, Finance and Management 28, no. 1 (2021): 3-34.
3. Liu, Mingxi, Guowen Li, Jianping Li, Xiaoqian Zhu, and Yinhong Yao. "Forecasting the price of Bitcoin using deep learning." Finance research letters 40 (2021): 101755.
4. Shahbazi, Zeinab, and Yung-Cheol Byun. "Knowledge Discovery on Cryptocurrency Exchange Rate Prediction Using Machine Learning Pipelines." Sensors 22, no. 5 (2022): 1740.
5. Ammer, Mohammed Abdullah, and Theyazn HH Aldhyani. "Deep Learning Algorithm to Predict Cryptocurrency Fluctuation Prices: Increasing Investment Awareness." Electronics 11, no. 15 (2022): 2349.
6. Li, Xiao, and Linda Du. "Bitcoin daily price prediction through understanding blockchain transaction pattern with machine learning methods." Journal of Combinatorial Optimization 45, no. 1 (2023): 4.
7. Yamin, Muhammad Abubakar, and Maham Chaudhry. "Cryptocurrency market trend and direction prediction using Machine Learning: A Comprehensive Survey." (2023).
8. Murshed, MG Sarwar, Christopher Murphy, Daqing Hou, Nazar Khan, Ganesh Ananthanarayanan, and Faraz Hussain. "Machine learning at the network edge: A survey." ACM Computing Surveys (CSUR) 54, no. 8 (2021): 1-37.
9. Verbraeken, Joost, Matthijs Wolting, Jonathan Katzy, Jeroen Kloppenburg, Tim Verbelen, and Jan S. Rellermeyer. "A survey on distributed machine learning." Acm computing surveys (csur) 53, no. 2 (2020): 1-33.
10. Burkart, Nadia, and Marco F. Huber. "A survey on the explainability of supervised machine learning." Journal of Artificial Intelligence Research 70 (2021): 245-317.
11. Wang, Meng, Weijie Fu, Xiangnan He, Shijie Hao, and Xindong Wu. "A survey on large-scale machine learning." IEEE Transactions on Knowledge and Data Engineering 34, no. 6 (2020): 2574-2594.
12. Meng, Tong, Xuyang Jing, Zheng Yan, and Witold Pedrycz. "A survey on machine learning for data fusion." Information Fusion 57 (2020): 115-129.
13. Wahab, Omar Abdel, Azzam Mourad, Hadi Otrouk, and Tarik Taleb. "Federated machine learning: Survey, multi-level classification, desirable criteria and future directions in communication and networking systems." IEEE Communications Surveys & Tutorials 23, no. 2 (2021): 1342-1397.
14. Dong, Shi, Ping Wang, and Khushnood Abbas. "A survey on deep learning and its applications." Computer Science Review 40 (2021): 100379.

15. Dargan, Shaveta, Munish Kumar, Maruthi Rohit Ayyagari, and Gulshan Kumar. "A survey of deep learning and its applications: a new paradigm to machine learning." *Archives of Computational Methods in Engineering* 27 (2020): 1071-1092.
16. Piccialli, Francesco, Vittorio Di Somma, Fabio Giampaolo, Salvatore Cuomo, and Giancarlo Fortino. "A survey on deep learning in medicine: Why, how and when?." *Information Fusion* 66 (2021): 111-137.
17. Raghu, Maithra, and Eric Schmidt. "A survey of deep learning for scientific discovery." *arXiv preprint arXiv:2003.11755* (2020).
18. Wang, Hao, and Dit-Yan Yeung. "A survey on Bayesian deep learning." *ACM computing surveys (csur)* 53, no. 5 (2020): 1-37.
19. Grigorescu, Sorin, Bogdan Trasnea, Tiberiu Cocias, and Gigel Macesanu. "A survey of deep learning techniques for autonomous driving." *Journal of Field Robotics* 37, no. 3 (2020): 362-386.
20. Hasan, ASM Mahmudul, Ferdous Sohel, Dean Diepeveen, Hamid Laga, and Michael GK Jones. "A survey of deep learning techniques for weed detection from images." *Computers and Electronics in Agriculture* 184 (2021): 106067.
21. Lim, Bryan, and Stefan Zohren. "Time-series forecasting with deep learning: a survey." *Philosophical Transactions of the Royal Society A* 379, no. 2194 (2021): 20200209.
22. Wang, Xizhao, Yanxia Zhao, and Farhad Pourpanah. "Recent advances in deep learning." *International Journal of Machine Learning and Cybernetics* 11 (2020): 747-750.
23. Torres, José F., Dalil Hadjout, Abderrazak Sebaa, Francisco Martínez-Álvarez, and Alicia Troncoso. "Deep learning for time series forecasting: a survey." *Big Data* 9, no. 1 (2021): 3-21.
24. Zohuri, Bahman, Hang T. Nguyen, and Masoud Moghaddam. "What is the Cryptocurrency." *Is it a Threat to Our National Security, Domestically and Globally, IJTC Physics* 3, no. 1 (2022): 1-14.
25. Wu, Jiajing, Jieli Liu, Yijing Zhao, and Zibin Zheng. "Analysis of cryptocurrency transactions from a network perspective: An overview." *Journal of Network and Computer Applications* 190 (2021): 103139.
26. Dimpfl, Thomas, and Dalia Elshiaty. "Volatility discovery in cryptocurrency markets." *The Journal of Risk Finance* 22, no. 5 (2021): 313-331.
27. Yadav, Satya Prakash, Krishna Kant Agrawal, Bhoopesh Singh Bhati, Fadi Al-Turjman, and Leonardo Mostarda. "Blockchain-based cryptocurrency regulation: An overview." *Computational Economics* 59, no. 4 (2022): 1659-1675.
28. Awotunde, Joseph Bamidele, Roseline Oluwaseun Ogundokun, Rasheed Gbenga Jimoh, Sanjay Misra, and Taye Oladele Aro. "Machine learning algorithm for cryptocurrencies price prediction." In *Artificial Intelligence for Cyber Security: Methods, Issues and Possible Horizons or Opportunities*, pp. 421-447. Cham: Springer International Publishing, 2021.
29. Lalithavani, J., S. Prasanna, and S. Keerthana. "IMPROVING THE CRYPTOCURRENCY PRICE PREDICTION PERFORMANCE BASED ON REINFORCEMENT LEARNING." *International Journal of Early Childhood Special Education* 14, no. 4 (2022).
30. Zarandi, M., & Jivan, S. E. (2015). *Effective Factors on Managers Decision-Making Style in Organizations (Viewpoints of Senior Executives using AHP*

Technique).

31. Metawa, Noura, Mohamemd I. Alghamdi, Ibrahim M. El-Hasnony, and Mohamed Elhoseny. "Return Rate Prediction in Blockchain Financial Products Using Deep Learning." *Sustainability* 13, no. 21 (2021): 11901.
32. Kang, Chuen Yik, Chin Poo Lee, and Kian Ming Lim. "Cryptocurrency Price Prediction with Convolutional Neural Network and Stacked Gated Recurrent Unit." *Data* 7, no. 11 (2022): 149.
33. Malhotra, Bhavay, Chittaranjan Chandwani, Pratham Agarwala, and Suman Mann. "Bitcoin Price Prediction Using Machine Learning and Deep Learning Algorithms." In *2022 10th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO)*, pp. 1-6. IEEE, 2022.
34. Sree, Ch Likhitha, M. Meghana, R. Manjula, and D. Mohan. "Bitcoin Price Prediction Using Machine Learning's Boosting Algorithms." In *Proceedings of Second International Conference on Sustainable Expert Systems: ICSES 2021*, pp. 115-125. Singapore: Springer Nature Singapore, 2022.
35. Oyedele, Azeez A., Anuoluwapo O. Ajayi, Lukumon O. Oyedele, Sururah A. Bello, and Kudirat O. Jimoh. "Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction." *Expert Systems with Applications* 213 (2023): 1.۱۹۲۳۳