



## ارائه مدل پیش‌بینی بازدهی بیت‌کوین با استفاده از روش هیبریدی یادگیری عمیق – الگوریتم تجزیه سیگنال (CEEMD- DL)

سکینه صیادی نژاد<sup>۱</sup>

علی اسماعیل زاده مقری<sup>۲</sup>

محمدرضا رستمی<sup>۳</sup>

تاریخ پذیرش: ۱۴۰۱/۱۲/۰۶

تاریخ دریافت: ۱۴۰۱/۱۰/۰۳

### چکیده

با افزایش محبوبیت و فراگیر شدن رمزارزها، ایجاد و توسعه روش‌های پیش‌بینی حرکت‌های قیمتی در این حوزه، توجهات زیادی را به خود جلب کرده‌است. در این بین مدل‌های یادگیری عمیق (DL) با ساختارهایی مانند حافظه طولانی کوتاه مدت (LSTM) و شبکه عصبی کانولوشنی (CNN) پیشرفت‌هایی در تحلیل این نوع از داده‌ها ایجاد کرده‌است. یکی دیگر از رویکردهایی که می‌تواند در تحلیل قیمتی بازار رمزارزها کارا باشد تجزیه سیگنال‌های از طریق الگوریتم‌هایی مانند تجزیه مد تجزیه یکپارچه کامل (CEEMD) می‌باشد. با توجه به اهمیت مقوله پیش‌بینی در بازار رمز ارزها، در این تحقیق با ترکیب مدل‌های یادگیری عمیق و روش تجزیه مد تجزیه یکپارچه کامل (CEEMD)، مدل هیبریدی (CEEMD- DL(LSTM)) به منظور پیش‌بینی بازدهی قیمتی رمز ارز بیت‌کوین (به عنوان محبوب‌ترین رمز ارز) مورد استفاده قرار گرفته‌است. در این راستا از داده‌های روزانه قیمتی بیت‌کوین در دوره زمانی ۲۰۱۳/۰۱/۰۱ - ۲۰۲۲/۰۵/۲۸ استفاده گردید و نتایج بدست آمده با نتایج مدل‌های رقیب بر اساس معیارهای سنجش کارایی مقایسه شد. بر اساس نتایج بدست آمده، استفاده از مدل معرفی شده (CEEMD- DL(LSTM))، کارایی و دقت پیش‌بینی‌های بازدهی رمزارز بیت‌کوین را افزایش داده‌است. بر همین اساس کاربرد این مدل به منظور پیش‌بینی در این حوزه پیشنهاد می‌گردد.

**واژه‌های کلیدی:** مدل‌های یادگیری عمیق (DL)، تجزیه مد تجزیه یکپارچه کامل (CEEMD)، بیت‌کوین، حافظه بلندمدت – کوتاه مدت (LSTM)، شبکه عصبی کانولوشنی (CNN).

طبقه بندی JEL: E37، C61، C45، G18

<sup>۱</sup> - گروه مالی، واحد علوم و تحقیقات دانشگاه آزاد اسلامی، تهران، ایران email: bsn231@yahoo.com

<sup>۲</sup> - گروه حسابداری واحد تهران مرکزی دانشگاه آزاد اسلامی تهران، ایران (نویسنده مسئول) email: alies35091@gmail.com

<sup>۳</sup> - گروه مدیریت، دانشگاه الزهراء تهران، ایران و گروه اقتصاد، واحد علوم و تحقیقات دانشگاه آزاد اسلامی، تهران، ایران.

email: m.rostami@alzahra.ac.ir



## ۱- مقدمه

در طول تکامل دانش پول (از قرن هجدهم)، بررسی‌های بنیادی زیادی در خصوص ماهیت واقعی و کارکرد اصلی پول انجام شده و رویکردها و نظریه‌های علمی پولی به طور قابل توجهی تغییر کرده‌است ولی تاکنون به حالت نهایی نرسیده‌است. قرن بیست و یکم که با توسعه وسیع فناوری‌ها و افزایش استفاده از اینترنت شناخته می‌شود، به طور قابل توجهی به توسعه سیستم پولی و معرفی یک پدیده جدید با عنوان پول‌های مجازی دست یافته است. مدت زیادی از طرح ایده و عملیاتی شدن پول مجازی نگذشته و پول‌های مجازی گوناگون، بازاری برای خود ایجاد کرده‌اند. پول‌های مجازی به دو دسته متمرکز و غیرمتمرکز تبدیل می‌شوند. پول‌های مجازی غیرمتمرکز اصطلاح ارزهای رمزپایه<sup>۱</sup> نامیده می‌شود. پول‌های مجازی متمرکز زیر نظر یک شرکت یا موسسه واسطه‌ای خاص فعالیت می‌کنند. مثلاً پی‌پال<sup>۲</sup> یک پول مجازی متمرکز است.

بیت‌کوین<sup>۳</sup> به عنوان پدر رمز ارزها و از محبوب‌ترین آنها در بازار شناخته می‌شود. از سال ۲۰۰۹ دنیای معاملات مالی شاهد خیزش بیت‌کوین همراه با شیفتگی در بازار و در بسیاری از موارد شک و تردید بوده‌است. به دلیل عدم وابستگی، امروزه بیت‌کوین به عنوان یک ارز قابل سرمایه‌گذاری آسان مطرح بوده و علاقه‌مندان زیادی را به سوی خود جذب نموده‌است. بیت‌کوین در یک کیف پول دیجیتال ذخیره شده که اساساً مانند یک حساب بانکی مجازی است. تمامی تراکنش‌های معاملاتی آن بر روی یک زنجیره اطلاعاتی بنام زنجیره بلوکی<sup>۴</sup> ذخیره می‌شود. هر رکورد در این زنجیره رمزنگاری شده و در طول معاملات، نام کاربری و مشخصات مالک پنهان می‌ماند و فقط شناسه کیف پول بصورت عمومی نشان داده می‌شود. بیت‌کوین از طریق یک شبکه هم‌تا به هم‌تا<sup>۵</sup> شامل زنجیره‌ای از بلوک‌های زمانی کنترل می‌شود. هر بلوک، لیستی از اطلاعات تراکنش‌ها را داراست و در آن همه اعضا با هم برابرند. (بونو و همکاران<sup>۶</sup>، ۲۰۱۵).

اگرچه حاکمیت‌ها نسبت به پذیرش این نوع از پول مقاومت نشان داده‌اند و برخوردهای متناقضی در این زمینه وجود دارد، اما مخترعان این پول‌ها و فعالان مالی با تلاش برای رفع چالش‌ها و ایجاد نوآوری‌های مالی در این عرصه، سعی در گسترش این پدیده دارند. علاوه بر این، مقامات اصلی مانند کمیسیون بورس و اوراق بهادار، وزارت خزانه‌داری و بانک مرکزی اروپا نگرانی‌های خود را در مورد این نوع جدید پول اعلام داشته‌اند. ولی با توجه به محبوبیت روزافزون ارزهای مجازی، به خصوص ارزهای رمزپایه یا ارزهای دیجیتال، مطالعه و پژوهش در این حوزه توجه زیادی را به خود جلب کرده‌است. چشم‌انداز گردش پول در جهان نشان می‌دهد که بیت‌کوین به عنوان یکی از ارزهای مجازی جای خود را در میان سایر پول‌ها باز کرده است.

البته یک جنبه ضروری که باید هنگام سرمایه‌گذاری در ارز مجازی در نظر گرفت، ریسک پیش‌فرض آن است. یعنی ریسک از دست دادن مقدار قابل توجهی از سرمایه‌گذاری اولیه. به عبارت دیگر، سقوط قیمت (کوین مارکت

<sup>1</sup> Cryptocurrency

<sup>2</sup> Paypal

<sup>3</sup> Bitcoin

<sup>4</sup> Block Chain

<sup>5</sup> Peer-to-peer

<sup>6</sup> Bonneau et al

کپ، ۲۰۱۷). از اینرو پیش‌بینی حرکت قیمتی ارزهای مجازی مورد توجه قرار گرفته و مدل‌های مختلفی در این حوزه در سطح جهانی مورد استفاده قرار گرفته است. از جمله روش‌هایی که در پیش‌بینی نوسانات و حرکت قیمتی رمز ارزها بسیار مورد توجه قرار گرفته است روش‌های هوشمند (یادگیری ماشین<sup>۱</sup>) می‌باشد. روش‌های هوشمند، الگوهای خطی و غیرخطی موجود در داده‌های مربوط به بازار را دنبال می‌کند تا بدین وسیله فرایند ایجاد آنها را حدس بزند. بر این اساس، در طول سال‌های پیش‌الگوریتم‌ها و نرم افزارهای زیادی با پیچیدگی‌ها و ساختارهای متفاوت برای این منظور پیشنهاد شده است (دولو و حیدری، ۱۳۹۶).

یادگیری ماشینی<sup>۲</sup> (ML)، شاخه‌ای از هوش مصنوعی است که با ابداع الگوریتم‌های مختلف، به تدریج عملکرد خود بر روی یک مسئله خاص را بهبود می‌بخشد. یادگیری ماشینی برای یافتن الگوها و کند و کاو تغییرات کوچک، بر پایه بررسی و مقایسه داده‌هایی از مقادیر کوچک تا حجم‌های عظیم داده استوار است. مطالعات بی-شماری منتشر شده است که پیش‌بینی‌ها براساس مدل‌های ML با عملکرد نسبتاً بهتری نسبت به تکنیک‌های پیش‌بینی سری زمانی کلاسیک انجام شده است. اخیراً در حوزه یادگیری ماشینی، گرایش‌ها با نام یادگیری عمیق<sup>۳</sup> (DL)، در پیش‌بینی‌های مالی، توجه بسیاری را جلب کرده است. یادگیری عمیق (DL) زیرمجموعه‌ای از کلاس گسترده‌تر از روش‌های یادگیری ماشین بر پایه شبکه‌های عصبی است. بررسی منابع صورت گرفته، نشان از کاربرد بالای تکنیک‌های DL در زمینه پیش‌بینی سری‌های زمانی مالی است. این مدل‌ها به طور معناداری، خطاهای کوچکتری را در پیش‌بینی نسبت به مدل‌های آماری نشان می‌دهند و دارای سرعت پیش‌بینی بالاتری هستند. با این‌که یادگیری عمیق در سال‌های ابتدایی توسعه خود قرار دارد، اما روند تحقیقات، مقالات و سرمایه‌گذاری‌های شرکت‌های بزرگ در این حوزه، نشان دهنده گسترش روز افزون کاربردهای یادگیری عمیق است. با توجه به ظرفیت‌ها و توانایی قابل توجه روش یادگیری عمیق در استخراج اطلاعات معتبر از مجموعه داده‌ها و الگوهای شناسایی قدرتمند، بسیاری از مقالات اخیر بر کاربرد تکنیک‌های DL در حوزه مالی متمرکز شده‌اند و ادغام الگوریتم‌های یادگیری عمیق با پیش‌بینی‌های بازار به عنوان یکی از جذاب‌ترین مباحث در ادبیات مالی در نظر گرفته می‌شود (کاوآنکاته و همکاران<sup>۴</sup>، ۲۰۱۶).

از طرفی دیگر، در سال‌های اخیر استفاده از روش‌های تجزیه سیگنال به عنوان روشی نوین و بسیار موثر در زمینه تجزیه و تحلیل سیگنال‌ها و سری‌های زمانی مورد توجه قرار گرفته است. در این روش سیگنال اصلی به چندین زیرسری تجزیه شده و داده‌های حاصل از تجزیه با معادلات مناسب برازش می‌یابد و مدل بدست آمده برای پیش‌بینی استفاده می‌شود. از جمله این روش‌ها روش جدید تجزیه مد تجربی یکپارچه کامل<sup>۵</sup> (CEEMD) است که در روند تجزیه سازی آن، حجم محدودی از نویز سفید وارد سیگنال اصلی شده و با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف

<sup>1</sup> Machine Learning

<sup>2</sup> Deep Learning

<sup>3</sup> Deep Learning

<sup>4</sup> Cavalcante et al.

<sup>5</sup> Complete Ensemble Empirical Mode Decomposition

می‌شود (ژانگ و همکاران<sup>۱</sup>، ۲۰۲۰). در این تحقیق تلاش می‌شود که مدل نوین و هیبریدی CEEMD-DL(LSTM<sup>۲</sup>) به منظور پیش‌بینی بازدهی قیمتی رمز ارز بیت‌کوین (به عنوان شاخص بازار رمز ارزها) معرفی و مورد استفاده قرار گیرد. انتظار می‌رود با استفاده از این رویکرد بتوان کارایی و دقت پیش‌بینی‌ها در این حوزه را افزایش داد.

در این بخش مقدمه‌ای جهت معرفی و بیان مسئله اصلی تحقیق بیان گردید در ادامه در بخش ۲ پیشینه داخلی و خارجی موضوع ارائه شده‌است. در بخش ۳ روش تحقیق و شرح مختصری از مدل‌های مورد استفاده بیان می‌شود. در بخش ۴ یافته‌های تحقیق و نتایج پیش‌بینی و ارزیابی عملکرد مدل CEEMD-DL(LSTM<sup>۳</sup>) ارائه می‌شود و در نهایت در بخش ۵ نتایج بدست آمده مورد بحث قرار می‌گیرد.

## ۲- ادبیات تحقیق

### ۲-۱ مبانی تحقیق

در بررسی تاریخی پی می‌بریم از زمانی که مفهوم پول مجازی به معنای پول رمزگذاری شده مطرح و ساتوشی ناکاموتو<sup>۴</sup> (۲۰۰۹) همزمان با رکود اقتصادی یک واحد بیت‌کوین را همراه الگوریتم ریاضی معرفی کرد و حتی تعریف بانک مرکزی اتحادیه اروپا (۲۰۱۲) از پول مجازی به عنوان نوعی پول دیجیتال و غیرقانونمند که به وسیله توسعه دهندگان آن صادر و کنترل می‌شود و توسط اعضا و کاربران جامعه مجازی مورد پذیرش و کاربرد قرار می‌گیرد، دیدگاه‌ها و استقبال نسبت به این نوع پول تفاوت پیدا کرده است تا آنجایی که از تنها سال ۲۰۱۳ تا ۲۰۱۷ تعداد ۱۰۹۱ ارز مجازی وجود داشته است (کوین مارکت کپ<sup>۵</sup>، ۲۰۱۷). این افزایش باعث ایجاد انگیزه برای مطالعه این موضوع شده است. به این معنا که اگر محبوبیت ارزهای مجازی بیش از این افزایش یابد باید مدل‌های مختلف ارزیابی و سنجش‌های مالی برای آن طراحی و آزمون شود.

یکی از ویژگی‌های اصلی بازار رمز ارز، نوسانات زیاد و ریسک سقوط قیمت رمز ارزها می‌باشد بنابراین استفاده از روش‌های کارا در پیش‌بینی روند حرکتی قیمت این بازار از اهمیت بالایی برخوردار است و باعث فعالیت‌های عمده‌ای در این حوزه شده است. استفاده از روش‌های هوش مصنوعی از جمله یادگیری عمیق در زمره اینگونه فعالیت‌ها هستند (لین و همکاران<sup>۶</sup>، ۲۰۲۱).

یادگیری عمیق زیرمجموعه‌ای از کلاس گسترده‌تر از روش‌های یادگیری ماشین و هوش مصنوعی بر پایه شبکه‌های عصبی است و به منظور تحلیل روش یادگیری عمیق، ساختار شبکه‌های عصبی مورد استفاده در ساختمان مدل‌های یادگیری عمیق می‌بایستی مورد بررسی قرار گیرد. پیشرفته‌ترین شبکه مورد استفاده در

<sup>1</sup> Zhang et al

<sup>2</sup> Long Short-Term Memory

<sup>3</sup> Long Short-Term Memory

<sup>4</sup> Satoshi Nakamoto

<sup>5</sup> Coinmarketcap

<sup>6</sup> Lin et al

پیش‌بینی‌های سری زمانی، ساختار حافظه طولانی کوتاه‌مدت یا (LSTM) است که در واقع یک نوع از شبکه‌های RNN<sup>۱</sup> می‌باشند. تفاوت اصلی RNN با ساختارهای دیگر این است که در این ساختار داده‌های ورودی دوره جاری و دوره‌های گذشته به صورت همزمان مورد استفاده قرار می‌گیرند و خروجی مدل در دوره جاری به داده‌های دوره قبل نیز بستگی دارد. از نظر تئوریک یک شبکه عصبی بازگشتی استاندارد (اگر به اندازه کافی بزرگ باشد) باید قادر به تولید دنباله‌هایی با هر پیچیدگی‌ای باشد اما در عمل این شبکه در ذخیره‌سازی اطلاعات مرتبط با ورودی‌های گذشته به مدت طولانی ناتوان است. علاوه بر اینکه این خصیصه توانایی این شبکه در مدل‌سازی ساختارهای بلندمدت را تضعیف می‌کند، این «فراموشی» باعث می‌شود تا این نوع از شبکه‌ها در زمان تولید دنباله در معرض ناپایداری قرار گیرند. مشکلی که وجود دارد، این است که اگر پیش‌بینی‌های شبکه تنها وابسته به چند ورودی اخیر باشد و این ورودی‌ها خود نیز توسط شبکه تولید شده باشند، شانس بسیار کمی برای تصحیح و جبران اشتباهات گذشته توسط شبکه وجود دارد. یک راه حل برای مشکل ذکر شده، اضافه کردن نوز به پیش‌بینی‌های صورت گرفته توسط شبکه قبل از تغذیه آنها به گام زمانی بعدی است. این کار باعث تقویت شبکه در قبال ورودی‌های غیرمنتظره می‌شود. با این وجود اما یک حافظه بهتر، راه حل به مراتب بهتر و تاثیرگذار تری است. حافظه طولانی کوتاه مدت یا (LSTM) یک معماری شبکه عصبی بازگشتی است که برای ذخیره‌سازی و دسترسی بهتر به اطلاعات نسبت به نسخه سنتی آن طراحی شده است.

برخلاف شبکه عصبی بازگشتی استاندارد (RNN) که در آن محتوا در هر گام زمانی از نو بازنویسی می‌شود در یک شبکه عصبی بازگشتی LSTM شبکه قادر است نسبت به حفظ حافظه فعلی از طریق دروازه‌های معرفی شده تصمیم‌گیری کند. به‌طور شهودی اگر واحد LSTM ویژگی مهمی در دنباله ورودی در گام‌های ابتدایی را تشخیص دهد به سادگی می‌تواند این اطلاعات را طی مسیر طولانی منتقل کند بنابراین می‌تواند این‌گونه وابستگی‌های بلندمدت احتمالی را دریافت و حفظ کند.

از دیگر رویکردهایی که به منظور افزایش کارایی پیش‌بینی‌های مالی می‌تواند مورد توجه قرار گیرد استفاده از الگوریتم‌های تجزیه سیگنال است. الگوریتم‌های تجزیه سیگنال، ابزارهای قدرتمندی هستند که می‌تواند برای جداسازی متغیر بازده دارایی‌های مالی ناشی از نوسانات در یک فرکانس خاص (یا افق زمانی) مورد استفاده قرار گیرد. معیارهای مبتنی بر فرکانس، به ما امکان می‌دهد بین اجزای اطلاعات بازده کوتاه‌مدت و بلندمدت تمایز قابل شویم، و بینش جدیدی در مورد قیمت‌گذاری دارایی‌ها، تخصیص پرتفوی و مدیریت ریسک ارائه دهیم. در پاسخ به پیشرفت‌های اخیر در یادگیری ماشینی و پردازش سیگنال، علاقه به استفاده از الگوریتم‌های تجزیه در مدل‌های پیش‌بینی وجود دارد. از طرف دیگر الگوریتم‌های تجزیه سیگنال، ابزارهای قدرتمندی هستند که می‌تواند برای جداسازی متغیر بازده دارایی‌های مالی ناشی از نوسانات در یک فرکانس خاص (یا افق زمانی) مورد استفاده قرار گیرد. معیارهای مبتنی بر فرکانس، به ما امکان می‌دهد بین اجزای اطلاعات بازده کوتاه‌مدت و بلندمدت تمایز قابل شویم، و بینش جدیدی در مورد قیمت‌گذاری دارایی‌ها، تخصیص پرتفوی و مدیریت ریسک ارائه دهیم. در

<sup>۱</sup> Recurrent Neural Networks

پاسخ به پیشرفت‌های اخیر در یادگیری ماشینی و پردازش سیگنال، علاقه به استفاده از الگوریتم‌های تجزیه در مدل‌های پیش‌بینی وجود دارد (ژانگ و همکاران<sup>۱</sup>، ۲۰۲۰).

## ۲-۲ پیشینه تحقیق

علیرغم قابلیت‌های بسیار زیاد مدل‌های یادگیری عمیق (DL) و افزایش روز افزون کاربرد این مدل‌ها در جهان در حوزه پیش‌بینی‌های بازارهای مالی، براساس بررسی‌های انجام شده در ایران مطالعات محدودی در این زمینه انجام شده است. در این بخش تلاش می‌شود به تعدادی از مطالعات داخلی و خارجی در این حوزه اشاره می‌شود.

محمدشریفی (۱۴۰۰) در تحقیقی به منظور پیش‌بینی قیمت بیت‌کوین از ترکیب مدل ARIMA و سه نوع شبکه عصبی عمیق شامل LSTM، RNN و GRU استفاده کرده است. هدف اصلی این پژوهش تعیین تاثیر مدل‌های یادگیری عمیق بر روی عملکرد پیش‌بینی قیمت آینده بیت‌کوین است. در مدل پیشنهادی ابتدا اجزای خطی موجود در مجموعه داده‌ها با استفاده از ARIMA جداسازی و باقیمانده‌های به دست آمده بصورت جداگانه به هر یک از شبکه‌های عصبی منتقل می‌شود. نتایج این تحقیق نشان می‌دهد که مدل ARIMA-GRU برای معیارهای RMSE و MAPE نسبت به سایر مدل‌ها نتایج بهتری داشته است. همچنین مدل‌های ترکیبی نسبت به مدل سنتی ARIMA در پیش‌بینی، عملکرد بهتری را از خود نشان می‌دهند.

بختیاران و ذوالفقاری (۱۴۰۰) در تحقیقی به طراحی مدلی جهت پیش‌بینی بازده بیت‌کوین (با تاکید بر مدل‌های ترکیبی شبکه عصبی کانولوشنی و بازگشتی و مدل‌های با حافظه بلندمدت) در دوره زمانی ۱۳۹۸-۱۳۹۲ پرداختند. یافته‌های این پژوهش نشان داد که مدل ترکیبی FIEGARCH-شبکه عصبی با توزیع تی-استیودنت در پیش‌بینی بازده بیت‌کوین کارآمدتر و دارای خطای پیش‌بینی کمتری نسبت به سایر مدل‌های رقیب است.

بشیری و پاریاب (۱۳۹۹) در تحقیق خود به پیش‌بینی قیمت بیت‌کوین با استفاده از الگوریتم‌های یادگیری ماشین پرداختند. در این پژوهش، مجموعه داده‌های مربوط به ده رمز ارز مورد استفاده قرار گرفت و یک مجموعه داده جدید، با در نظر گرفتن قیمت نهایی هر رمز ارز و برای دستیابی به هدف تحقیق و تعیین این‌که چگونه جهت و صحت قیمت بیت‌کوین را می‌توان با استفاده از تکنیک‌های داده کاوی پیش‌بینی کرد، تشکیل شد. در این پژوهش الگوریتم‌های ماشین بردار پشتیبان، جنگل تصادفی، گرادیان تقویتی و شبکه عصبی مقدار صحت ۵۲/۱۶ درصد را ثبت کردند.

صالحی فر (۱۳۹۸) در پژوهشی با استفاده از مدل‌های تک متغیره TGARCH، GJR-GARCH و و ضریب همبستگی اسپیرمن بازدهی و ریسک معاملات بیت‌کوین در مقایسه با سایر بازارهای رقیب مانند ارز (دلار و یورو)، بورس و طلا (قراردادهای آتی طلا و سکه بهار آزادی) را بررسی کرده‌اند. در نهایت در این مطالعه چنین نتیجه‌گیری می‌شود که اگرچه نتایج نشان می‌دهد بازده و ریسک بیت‌کوین نسبت به سایر فرصت‌های سرمایه‌گذاری مانند ارز، طلا، سکه و بورس در داخل کشور به طور قابل ملاحظه‌ای بیشتر است اما بدلیل ویژگیهای متفاوت

<sup>1</sup> Zhang et al

ریسک و بازده منحصر به فرد در بیت‌کوین، نمی‌توان آن را با سایر دارایی‌ها مقایسه نمود و رفتار آن را از نظر ریسک و بازدهی با بازارهای رقیب مرتبط دانست.

باباجانی و همکاران (۱۳۹۸) در تحقیقی با عنوان پیش‌بینی قیمت سهام در بورس تهران با استفاده از شبکه عصبی بازگشتی بهینه شده با الگوریتم کلونی زنبورعسل مصنوعی به ارائه مدلی بهینه برای پیش‌بینی قیمت سهام در بورس تهران پرداختند. در این تحقیق از داده‌های سهام پذیرفته‌شده در بورس اوراق بهادار تهران طی سال‌های ۱۳۹۰ تا پایان سال ۱۳۹۴ و الگوریتم کلونی زنبورعسل مصنوعی (ABC) در یک فضای طراحی پارامتری، برای بهینه کردن وزن‌ها و تورش‌های شبکه عصبی بازگشتی استفاده کردند. نتایج این تحقیق نشان می‌دهد که استفاده از شبکه عصبی بهینه‌شده با الگوریتم کلونی زنبورعسل مصنوعی، دقت قابل‌ملاحظه‌ای در مقایسه با سایر روش‌های پیش‌بینی دارد.

شنگاو و همکاران<sup>۱</sup> (۲۰۲۲) در تحقیقی با استفاده از تجزیه و تحلیل تجربی پیش‌بینی قیمت بیت‌کوین بر اساس روش هیبریدی یادگیری عمیق پرداختند. در این تحقیق با ادغام دو مدل روش یادگیری عمیق رمزگذاری نوین زدایی انباشته (SDAE) و روش تجمیع بوت استرپ<sup>۲</sup> روشی جدید و هیبریدی برای پیش‌بینی قیمت بیت‌کوین ارائه شد. نتایج این تحقیق نشان می‌دهد که روش پیشنهادی در مقایسه با مدل‌های انفرادی از دقت بالاتری برخوردار است و ویژگی غیر خطی بودن سری زمانی بیت‌کوین به صورت بهتری توضیح می‌دهد.

جاکورت و همکاران<sup>۳</sup> (۲۰۲۱) در تحقیق خود پیش‌بینی پذیری بازار بیت‌کوین را در افق‌های زمانی کوتاه مدت از ۱ تا ۶۰ دقیقه تجزیه و تحلیل کردند. در این تحقیق از ساختارهای مختلف یادگیری عمیق و مجموعه‌ای از ویژگی‌های جامع، از جمله ویژگی‌های فنی، مبتنی بر بلاک‌چین، مبتنی بر احساسات/علاقه و ویژگی‌های مبتنی بر دارایی استفاده کردند. نتایج این تحقیق نشان می‌دهد که ویژگی‌های فنی برای اکثر روش‌ها معنادار هستند و به دنبال آن ویژگی‌های انتخابی مبتنی بر بلاک‌چین و مبتنی بر احساسات/علاقه قرار دارند. علاوه بر این نتایج این تحقیق نشان می‌دهد که قابلیت پیش‌بینی برای افق‌های پیش‌بینی طولانی‌تر افزایش می‌یابد.

لین و همکاران<sup>۴</sup> (۲۰۲۱) در تحقیق خود تلاش کردند که شاخص‌های بازارهای بزرگ سهام دنیا را با استفاده از ترکیب روش‌های یادگیری عمیق و الگوریتم‌های تجزیه سیگنال پیش‌بینی کنند در این راستا از ساختارهای متنوعی در مدل‌های یادگیری عمیق و الگوریتم‌های تجزیه سیگنال استفاده می‌کنند و در نهایت مدل ترکیبی یادگیری عمیق با ساختار LSTM و الگوریتم CEEMDAN را به عنوان مدل بهینه در پیش‌بینی‌های مالی در بازارهای نوظهور معرفی می‌کنند.

یاماک و همکاران<sup>۵</sup> (۲۰۱۹) در پژوهشی، عملکرد مدل‌های مختلف یادگیری عمیق را به همراه مدل میانگین متحرک خود همبسته یکپارچه برای پیش‌بینی داده‌های بیت‌کوین مقایسه نمودند. آنها از شبکه عصبی عمیق

<sup>1</sup> Shengao et al

<sup>2</sup> Stacking Denoising Autoencoders

<sup>3</sup> Bootstrap Aggregation

<sup>4</sup> Jaquart et al

<sup>5</sup> Lin et al

<sup>6</sup> Yamak et al.

LSTM و واحد بازگشتی دروازه‌های برای مقایسه با مدل سنتی استفاده نمودند. نتایج این مطالعه نشان می‌دهد مدل میانگین متحرک خود همبسته یکپارچه در مقایسه با شبکه عصبی عمیق از عملکرد بهتری برخوردار است. کاراکویون و سیبیل دیکن<sup>۱</sup> (۲۰۱۸) به مقایسه مدل سری زمانی میانگین متحرک خود همبسته یکپارچه با مدل LSTM در پیش‌بینی قیمت بیت‌کوین پرداختند. آنها برای ارزیابی مدل از ۲ شاخص ارزیابی خطای MAPE استفاده نمودند. نتایج این مطالعه حاکی از عملکرد بهتر مدل LSTM در مقایسه با میانگین متحرک خود همبسته یکپارچه می‌باشد.

سین و وانگ<sup>۲</sup> (۲۰۱۷) با در نظر گرفتن رابطه بین ویژگی‌های بیت‌کوین و تغییرات قیمت روز بعد آن، مدلی ترکیبی بر پایه شبکه عصبی پرسپترون چند لایه و الگوریتم ژنتیک ارائه نمودند. آنها برای درک بهتر اثربخشی و کاربرد آن در دنیای واقعی، از مدل ترکیبی برای پیش‌بینی قیمت بیت‌کوین در روز بعد استفاده نمودند. نتایج آن‌ها نشان داد، در بازه زمانی ۵۰ روز، یک استراتژی معاملاتی مبتنی بر مدل ترکیبی در برابر یک استراتژی معاملاتی مبتنی بر قیمت روز قبل، بازده ۸۵ درصدی را نشان می‌دهد. این درحالی‌است که استراتژی معاملاتی مبتنی بر قیمت روز قبل تنها ۳۸ درصد بازده ایجاد کرده‌است.

نتایج تحقیقات ارائه شده در این بخش به صورت کلی نشان‌دهنده کارایی و عملکرد بهتر مدل‌های مبتنی بر یادگیری ماشین و هوش مصنوعی در پیش‌بینی متغیرهای مالی است. علاوه بر این، نتایج ارائه شده نشان می‌دهد که ادغام روش‌های مختلف می‌تواند کارایی مدل‌های پیش‌بینی متغیرهای مالی را افزایش دهد. در این تحقیق تلاش شده است مدل یادگیری عمیق مبتنی بر (LSTM) با الگوریتم‌های تجزیه سری‌های زمانی به منظور افزایش کارایی پیش‌بینی بازده رمز ارز بیت‌کوین ترکیب شود و از این جهت مدل ارائه شده در مقایسه با مدل‌های پیشین در این حوزه از نوآوری قابل ملاحظه‌ای برخوردار می‌باشد.

### ۳- روش تحقیق

روش پژوهش حاضر از لحاظ هدف کاربردی و از لحاظ ماهیت و روش علمی است. همچنین از نظر ویژگی و جهت داده‌ها پس‌رویدادی و از طریق اطلاعات گذشته می‌باشد. در تحقیق حاضر برای جمع‌آوری منابع نظری از روش کتابخانه‌ای و داده‌های این تحقیق از سایت [coinmarketcap.com](http://coinmarketcap.com) که در ارتباط با ارزش‌های مجازی از اعتبار بالایی در سطح جهان برخوردار است جمع‌آوری شده است. در این تحقیق از داده‌های روزانه رمز ارز بیت‌کوین به عنوان شاخص بازار رمز ارز در دوره زمانی ۲۰۱۳/۰۱/۰۱ - ۲۰۲۲/۰۵/۲۸ استفاده شده است.

### ۳-۱ مدل تحقیق

همانطور که بیان گردید یادگیری عمیق زیرمجموعه‌ای از کلاس گسترده‌تر از روش‌های یادگیری ماشین و هوش مصنوعی بر پایه شبکه‌های عصبی است و به منظور تحلیل روش یادگیری عمیق، ساختار شبکه‌های عصبی مورد

<sup>1</sup> Karakoyun & Cibikdiken

<sup>2</sup> Sin et al



استفاده در ساختمان مدل‌های یادگیری عمیق می‌بایستی مورد بررسی قرار گیرد. لازم به ذکر است که کارایی پیش‌بینی متغیرهای مالی و اقتصادی با استفاده از شبکه‌های عصبی در مطالعات زیادی از جمله امامی و امام وردی (۱۳۸۸)، باغستانی و همکاران (۱۳۹۴) تایید شده است. پیشرفته‌ترین شبکه مورد استفاده در پیش‌بینی‌های سری زمانی، ساختار حافظه طولانی کوتاه‌مدت یا (LSTM) است که در واقع یک نوع از شبکه‌های RNN می‌باشند. تفاوت اصلی RNN با ساختارهای دیگر این است که در این ساختار داده‌های ورودی دوره جاری و دوره‌های گذشته به صورت همزمان مورد استفاده قرار می‌گیرند و خروجی مدل در دوره جاری به داده‌های دوره قبل نیز بستگی دارد. از نظر تئوریک یک شبکه عصبی بازگشتی استاندارد (اگر به اندازه کافی بزرگ باشد) باید قادر به تولید دنباله‌هایی با هر پیچیدگی‌ای باشد اما در عمل مشاهده می‌کنیم که این شبکه در ذخیره‌سازی اطلاعات مرتبط با ورودی‌های گذشته به مدت طولانی ناتوان است. علاوه بر اینکه این خصیصه توانایی این شبکه در مدل‌سازی ساختارهای بلند مدت را تضعیف می‌کند، این «فراموشی» باعث می‌شود تا این نوع از شبکه‌ها در زمان تولید دنباله در معرض ناپایداری قرار گیرند. مشکلی که وجود دارد، این است که اگر پیش‌بینی‌های شبکه تنها وابسته به چند ورودی اخیر باشد و این ورودی‌ها خود نیز توسط شبکه تولید شده باشند، شانس بسیار کمی برای تصحیح و جبران اشتباهات گذشته توسط شبکه وجود دارد. یک راه حل برای مشکل ذکر شده، تزریق نویز به پیش‌بینی‌های صورت گرفته توسط شبکه قبل از تغذیه آنها به گام زمانی بعدی است. این کار باعث تقویت شبکه در قبال ورودی‌های غیرمنتظره می‌شود. با این وجود اما یک حافظه بهتر، راه حل به مراتب بهتر و تاثیرگذار تری است. حافظه طولانی کوتاه مدت یا (LSTM) یک معماری شبکه عصبی بازگشتی است که برای ذخیره‌سازی و دسترسی بهتر به اطلاعات نسبت به نسخه سنتی آن طراحی شده است.

برخلاف شبکه عصبی بازگشتی استاندارد (RNN<sup>۱</sup>) که در آن محتوا در هر گام زمانی از نو بازنویسی می‌شود در یک شبکه عصبی بازگشتی LSTM شبکه قادر است نسبت به حفظ حافظه فعلی از طریق دروازه‌های معرفی شده تصمیم‌گیری کند. بطور شهودی اگر واحد LSTM ویژگی مهمی در دنباله ورودی در گام‌های ابتدایی را تشخیص دهد به سادگی می‌تواند این اطلاعات را طی مسیر طولانی منتقل کند بنابر این این گونه وابستگی‌های بلندمدت احتمالی را دریافت و حفظ دارد.

شبکه‌های LSTM از واحدهای LSTM تشکیل شده‌اند. واحدهای LSTM با هم ادغام می‌شود و یک لایه LSTM تشکیل می‌شود. یک واحد LSTM از سلول‌هایی تشکیل شده است که دارای گیت ورودی<sup>۲</sup>، گیت خروجی<sup>۳</sup> و گیت فراموشی<sup>۴</sup> می‌باشد. سه گیت ذکر شده جریان اطلاعات را تنظیم می‌کند. با استفاده از این ویژگی‌ها، هر سلول مقادیر مورد نظر در فواصل زمانی دلخواه را حفظ می‌کند. معادلات (۱) تا (۵) فرم عمومی شبکه LSTM را نشان می‌دهد.

<sup>۱</sup> Recurrent Neural Networks

<sup>۲</sup> Input gate

<sup>۳</sup> Output gate

<sup>۴</sup> Forget gate

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \quad (3)$$

$$c_t = f_t * c_{t-1} + i_t * \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \quad (4)$$

$$h_t = o_t * \sigma_h(c_t) \quad (5)$$

در اینجا  $x_t$ ، بردار ورودی واحد LSTM،  $f_t$  بردار فعال سازی گیت فراموشی،  $i_t$  بردار فعال سازی گیت ورودی،  $o_t$  بردار فعال سازی گیت خروجی،  $h_t$  بردار خروجی واحد LSTM،  $c_t$  بردار حالت سلول،  $\sigma$  تابع سیگموئید،  $\sigma_c$  تابع تانژانت هایپربولیک،  $W$ ،  $U$ : ماتریس های وزن که باید آموزش داده شده و برازش شوند و  $b$  پارامترهای بردار بایاس هستند. لازم به ذکر است که منظور از گیت، یک دریچه یا پیچ قابل تنظیم است که به ما امکان کنترل می‌دهد. گیت ورودی، ورود یک سری اطلاعات جدید به حافظه بلندمدت را بررسی می‌کند؛ گیت فراموشی، گیتی است که به شبکه LSTM این قابلیت را می‌دهد که بعضی از مولفه‌های موجود در  $C_{t-1}$  فراموش شوند و گیت خروجی، دو ورودی  $x_t$  و  $h_{t-1}$  را وارد دو لایه فولی کانکت می‌کند و پس از جمع در نهایت از تابع سیگموئید عبور می‌دهد.

### ۳-۲ مدل CEEMD-DL(LSTM)


روش تجزیه مد تجربی (EMD) روشی برای تجزیه سری‌های زمانی گوناگون است که این عمل در فرآیندی تحت عنوان غربال کردن صورت می‌گیرد. طی این فرایند سری زمانی اصلی به تعدادی مولفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD طبق رابطه (۶) سری زمانی اصلی  $x(n)$  را به تعدادی توابع مد ذاتی ( $IMF^1$ ) تجزیه می‌کند. توابع مد ذاتی (IMF) بخش‌هایی از سری زمانی با فرکانس تقریباً یکسان می‌باشند.

$$x(n) = \sum_{i=1}^n c_i(x) + r_n(x) \quad (6)$$

که  $r_n(x)$  همان مولفه باقیمانده، بعد از  $n$  تعداد IMFها و  $c_i(x)$  است. یک داده ممکن است در یک زمان دارای چندین مد ذاتی باشد. این مدهای نوسانی، تابع‌های مد ذاتی (IMF) نام دارند و دارای دو شرایط هستند. ۱. در کل داده‌ها، تعداد نقاط فرین (اکسترمم) و نقاط صفر با هم برابر و یا حداکثر دارای یک واحد اختلاف هستند. ۲. در هر نقطه میانگین پوش برازش داده شده بر نقاط بیشینه محلی و پوش برازش داده شده بر نقاط کمینه محلی باید صفر باشد. به علت وجود تناوب و نویز در سری‌های زمانی، در برخی موارد به علت اختلاط مدها؛ توزیع حوزه زمان-فرکانس دچار انقطاع می‌شود و عملکرد EMD دچار نقض می‌گردد (چون میانگین IMF ها حالتی

<sup>1</sup> Intrinsic Mode Functions

نامشخص به خود می‌گیرد). جهت رفع این ایراد، وو و هوانگ (۲۰۰۴) روشی متفاوت با عنوان روش تجزیه مد تجزیه‌ی یکپارچه کامل (CEEMD) ارائه گردید. در روند تجزیه‌ی سازی این روش، حجم محدودی از نویز سفید<sup>۱</sup> وارد سری زمانی اصلی می‌شود. براساس تعریف، نویز سفید، دنباله‌ای از مقدارهای وابسته به زمان هستند که به یکدیگر مرتبط یا وابستگی ندارند بطوری که میانگین مقدارها برابر با صفر است. در چنین حالتی، جملات خطاها را می‌توان مستقل و هم توزیع<sup>۲</sup> در نظر گرفت. با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف می‌شود. در این روش جزء نوفه سفید بصورت دوتایی (یکی مثبت و دیگری منفی) به داده اصلی اضافه می‌شود تا دو سری IMF مجموع ساخته شود. بنابراین ترکیبی متشکل از داده اصلی و نوفه سفید اضافه شده داریم که مجموع IMFها برابر سری زمانی اصلی می‌شود و نوفه اضافی دامنه موجی از مرتبه pm خواهد بود. در پایان این بخش، شکل (۱) فرایند کلی مدل ارائه شده در این تحقیق CEEMD- DL(LSTM) را ارائه می‌کند. همانطور که در شکل (۱) قابل ملاحظه می‌باشد در مدل ارائه شده ابتدا با استفاده از الگوریتم CEEMD سری زمانی اصلی به توابع مدهای ذاتی (IMF) تجزیه می‌گردد و در ادامه و پس از نرمال سازی در قالب مدل‌های یادگیری عمیق با ساختار LSTN مورد تحلیل قرار گرفته و در نهایت نتایج با استفاده از قواعد خاص تجمیع و پیش‌بینی نهایی بدست می‌آید.



شکل ۱- فرایند کلی تجزیه و تجمیع در مدل CEEMD- DL(LSTM)

منبع: یافته‌های پژوهشگر

<sup>1</sup> White Noise

<sup>2</sup> Independent and Identically Distributed – iid

### ۳-۴ معیارهای ارزیابی

برای ارزیابی کارایی روش‌های پیش‌بینی سری زمانی بازدهی قیمتی بیت‌کوین، از سه معیار اصلی استفاده می‌شود:

(۱) میانگین درصد قدرمطلق خطای متقارن (SMAPE<sup>1</sup>)

(۲) میانگین مطلق درصد خطا<sup>۲</sup> (MAPE)

(۳) ریشه میانگین مربع خطا<sup>۳</sup> (RMSE<sup>3</sup>)

این معیارها به صورت روابط زیر تعریف می‌گردند

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{\frac{|\hat{y}_t| + |y_t|}{2}} \times 100 \quad (7)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{|y_t|} \times 100 \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (9)$$

جاییکه  $\hat{y}_t$  و  $y_t$  به ترتیب مقادیر واقعی و پیش‌بینی شده در زمان  $t$  می‌باشند.

### ۴- نتایج برآورد مدل های تحقیق

در این تحقیق تلاش می‌شود که مدل نوین و هیبریدی CEEMD-DL(LSTM) به منظور پیش‌بینی بازدهی بیت‌کوین به عنوان پراکسی بازار رمز ارز معرفی و مورد استفاده قرار گیرد. در این راستا و به منظور دستیابی به حجم داده‌های کافی برای اجرای مدل تحقیق و همچنین حذف سال‌های ابتدایی که بازار رمز ارز از شهرت و معاملات محدودی برخوردار بوده‌است از داده‌های روزانه رمز ارز بیت‌کوین در دوره زمانی ۲۰۱۳/۰۱/۰۱ - ۲۰۲۲/۰۵/۲۸ استفاده شده‌است. لازم به ذکر است به منظور محاسبه‌ی بازدهی نیز به این ترتیب عمل شده است که اگر قیمت رمز ارز بیت‌کوین در دوره  $t$  را با  $P_t$  نشان دهیم آنگاه می‌توان لگاریتم بازده را در لحظه  $t$  به صورت معادله (۱۰) محاسبه نمود:


$$r_{it} = \log\left(\frac{P_{it}}{P_{it-1}}\right) \times 100 \quad (10)$$

<sup>1</sup> Symmetric Mean Absolute Percentage Error (SMAPE)

<sup>2</sup> Mean Absolute Percentage Error (MAPE)

<sup>3</sup> Root Mean Square Error (RMSE)

در نمودار (۱) نمایی کلی از روند قیمتی رمزارز بیت‌کوین در دوره مورد بررسی ارائه شده است.




نمودار ۱- روند قیمتی رمز ارز بیت‌کوین / دلار

منبع: یافته‌های پژوهشگر

#### ۲-۴ برآورد مدل هیبریدی CEEMD-DL(LSTM)

در این بخش و در روند تجزیه سری زمانی، داده‌های بازدهی قیمت در رمز ارز بیت‌کوین با استفاده از الگوریتم CEEMD به مولفه‌ها مختلف با بسامدهای مختلف تجزیه می‌شود. به بیان دیگر سری زمانی بازدهی قیمت بیت‌کوین به توابع مد ذاتی (IMFs) و یک جمله اخلاص تجزیه می‌شود. واضح است که فرایند آموزش شبکه بر روی توابع مد ذاتی با بسامد کمتر راحت‌تر از توابع مد ذاتی با بسامد بیشتر می‌باشد. در نمودار (۲) و جدول (۱) نتایج تجزیه سری زمانی بازدهی قیمت بیت‌کوین با استفاده از الگوریتم CEEMD ارائه شده است.



نمودار ۲- تجزیه سری زمانی بازدهی قیمت بیت‌کوین با استفاده از الگوریتم CEEMD  
منبع: یافته‌های پژوهشگر

جدول ۱- آمار توصیفی توابع مددانی استخراج شده از الگوریتم CEEMD

	میانگین	ماکزیمم	مینیمم	انحراف استاندارد	چولگی	کشیدگی
IMF1	۰/۰۲۷۴	۲۴/۹۴	۲۰/۸۸	۳/۶۶۴	۰/۰۰۸۷	۷/۳۸۷
IMF2	۰/۰۴۴۴	۱۲/۶۱	-۱۳/۰۷	۲/۱۱۶	۰/۰۵۴	۷/۱۲۸
IMF3	۰/۰۶۱۱	۶/۲۴۷	-۵/۷۳۴	۱/۳۳۳	۰/۱۱۶۷	۴/۴۰۳
IMF4	۰/۰۰۴۷	۴/۶۱۷	-۴/۹۴۳	۱/۰۱۸	۰/۱۳۰	۴/۸۱۲
IMF5	-۰/۰۰۵۷	۲/۳۵۰	-۲/۸۲۳	۰/۷۰۱	-۰/۲۸۵	۴/۲۵۶
IMF6	-۰/۰۰۰۶	۲/۲۶۷	-۲/۳۱۳	۰/۶۷۳	۰/۲۶۶۶	۵/۹۶۶
IMF7	۰/۰۰۱۶	۰/۵۴۹۷	-۰/۴۸۱۲	۰/۲۵۹۳	۰/۲۲۲۲	۲/۰۳۳
IMF8	-۰/۰۰۱۵	۰/۴۶۵۷	-۰/۴۶۵۱	۰/۲۵۵۱	-۰/۱۶۷۲	۱/۷۹۹
RESINF	۰/۲۲۲۳	۰/۷۳۳۶	۰/۰۳۷۶	۰/۱۷۵۱	۱/۳۹۴	۳/۸۳۵

منبع: یافته‌های پژوهشگر

پس از تجزیه سری اصلی بازدهی قیمت بیت‌کوین به طیف‌های بسامدی مختلف با استفاده از الگوریتم CEEMD، قبل از فرایند یادگیری لازم است داده‌های مورد استفاده نرمالایز شوند. به این منظور از رابطه (۱۱) استفاده می‌شود.

$$X_{in} = \frac{x_i(t) - \mu x_i(t)}{\sigma x_i(t)} \quad (11)$$


جاییکه  $x_i(t)$  نشان دهنده آامین داده از IMF،  $\mu x_i(t)$  میانگین IMF،  $\sigma x_i(t)$  انحراف معیار و  $X_{in}(t)$  داده‌های نرمال شده می‌باشند. لازم به ذکر از که می‌توان با استفاده از معکوس رابطه (۱۰) به داده‌های اصلی را بدست آورد. در جدول (۲) تنظیمات هایپر پارمترهای مدل که بر اساس برآورد چندین مدل و انتخاب مدل با بالاترین کارایی برای imf های مختلف انجام شده‌است را نشان می‌دهد.

جدول ۲- تنظیمات هایپر پارامترهای مدل LSTM

	MiniBatchSize	Epoch	Initial Learn Rate
IMF1	۳	۶۰۰	۰/۰۰۵
IMF2	۳	۴۷۰	۰/۰۰۵
IMF3	۳	۴۰۰	۰/۰۰۵
IMF4	۲	۳۷۰	۰/۰۰۵
IMF5	۲	۳۵۰	۰/۰۰۵
IMF6	۲	۳۵۰	۰/۰۰۵
IMF7	۲	۳۵۰	۰/۰۰۵
IMF8	۳	۳۵۰	۰/۰۰۵
Residual	۷	۳۵۰	۰/۰۰۵

منبع: یافته‌های پژوهشگر


در ادامه، هشت تابع ذاتی استخراج شده در مرحله قبل، بر اساس مدل یادگیری عمیق با ساختار لایه‌های (LSTM) و تنظیمات جدول (۱) در فرایند آموزش قرار می‌گیرند و در ادامه با استفاده از فرایند تجمیع سازی نهایی، سری بازدهی قیمت رزم ارز بیت‌کوین در دوره آزمون (۳۳۰ مشاهده انتهایی) پیش‌بینی گردید. نمودار (۳) و (۴) به ترتیب نتایج پیش‌بینی توابع مد ذاتی و نتایج نهایی پیش‌بینی بازدهی قیمت رمزارز بیت‌کوین در دوره آزمون مدل را نشان می‌دهد.



نمودار ۳- نتایج پیش‌بینی توابع مد ذاتی با استفاده از مدل LSTM

منبع: یافته‌های پژوهشگر





نمودار ۴- پیش‌بینی بازدهی قیمت بیت‌کوین و با استفاده از روش CEEMD-DL(LSTM)  
منبع: یافته‌های پژوهشگر

### ۳-۴ سنجش کارایی مدل‌های تحقیق

در ادامه و به منظور بررسی کارایی مدل نهایی تحقیق، از معیارهای سنجش کارایی استفاده می‌شود. در این تحقیق از سه معیار میانگین درصد قدرمطلق خطای متقارن (SMAPE)، میانگین مطلق درصد خطا (MAPE) و ریشه میانگین مربع خطا (RMSE) استفاده می‌شود. نتایج محاسبه معیارهای سنجش کارایی مربوط به مدل اصلی تحقیق CEEMD-DL(LSTM) و دو مدل معرفی شده و پرکاربرد در این حوزه در جدول (۲) ارائه شده است. نتایج ارائه شده در این جدول حاکی از کارایی مدل CEEMD-DL(LSTM)، نسبت به دو مدل دیگر می‌باشد. مدل یادگیری عمیق با ساختار LSTM در مقام بعدی از لحاظ کارایی قرار می‌گیرد. نتایج جدول (۲) نشان‌دهنده تاثیر مثبت استفاده از الگوریتم‌های تجزیه سیگنال در افزایش کارایی مدل‌های یادگیری عمیق می‌باشد.

جدول ۳- نتایج معیارهای سنجش کارایی

	RMSE	SMAPE	MAPE
CEEMD-DL(LSTM)	۱۶۴/۱۳	۰/۱۸۸۷	۰/۰۰۳۰
DL(CNN)	۱۶۸/۷۴	۰/۲۰۶۲	۰/۰۰۳۲
DL(LSTM)	۲۳۸/۲۹	۰/۸۷۷۱	۰/۰۰۳۸

منبع: یافته‌های پژوهشگر

## ۵- بحث و نتیجه‌گیری

در سال‌های اخیر بیت‌کوین به عنوان محبوب‌ترین رمز ارز، مورد توجه بسیاری از سرمایه‌گذاران و فعالان اقتصادی قرار گرفته است. بازار رمز ارزها نوسان به شدت زیادی را تجربه کرده است و یکی از اصلی‌ترین چالش‌های پیش روی آن، پیش‌بینی قیمت آینده است. بدون شک، ایجاد و توسعه روش‌ها و مدل‌ها برای پیش‌بینی قیمت بیت‌کوین بسیار مورد توجه قرار گرفته و تاثیر بسیار زیادی در تعیین سود و زیان حاصل از فعالیت در این حوزه در آینده دارد.

از طرفی دیگر اخیراً در حوزه یادگیری ماشینی، گرایشی یادگیری عمیق (DL)، در پیش‌بینی‌های مالی، توجه بسیاری را جلب کرده است. با این که یادگیری عمیق در سال‌های ابتدایی توسعه خود قرار دارد، اما روند تحقیقات، مقالات و سرمایه‌گذاری‌های شرکت‌های بزرگ در این حوزه، نشان‌دهنده گسترش روز افزون کاربردهای یادگیری است. با توجه به ظرفیت‌ها و توانایی قابل توجه روش یادگیری عمیق در استخراج اطلاعات معتبر از مجموعه داده‌ها و الگوهای شناسایی قدرتمند، بسیاری از مقالات اخیر بر کاربرد تکنیک‌های DL در حوزه مالی متمرکز شده‌اند و ادغام الگوریتم‌های یادگیری عمیق با پیش‌بینی‌های بازار به عنوان یکی از جذاب‌ترین مباحث در ادبیات مالی در نظر گرفته می‌شود (کاوآنکاتنه و همکاران، ۲۰۱۶). علاوه بر این، رویکرد تجزیه سیگنال در این حوزه از جمله حرکت‌های است که می‌تواند در تحلیل سری‌های زمانی مالی کارا باشد.

در این تحقیق به منظور افزایش کارایی و دقت پیش‌بینی‌ها در بازار رمز ارزها، مدل هیبریدی یادگیری عمیق مبتنی بر ساختار شبکه‌های عصبی (LSTM) و با استفاده از الگوریتم تجزیه مد تجربی یکپارچه کامل (CEEMD) ارائه گردید. در ادامه نتایج پیش‌بینی بازدهی قیمتی بیت‌کوین (به عنوان محبوب‌ترین رمز ارز) بر اساس این مدل (CEEMD-DL(LSTM)) با نتایج مدل‌های پر کاربرد در این حوزه مقایسه گردید. در این راستا از معیارهای سنجش کارایی میانگین درصد قدرمطلق خطای متقارن (SMAPE)، میانگین مطلق درصد خطا (MAPE) و ریشه میانگین مربع خطا (RMSE) استفاده شد. بر اساس نتایج این تحقیق، مدل پیشنهادی (CEEMD-DL(LSTM)) نسبت به دو مدل رقیب مبتنی بر ساختارهای LSTM و CNN از عملکرد بهتری برخوردار می‌باشد. نتایج این تحقیق، یافته‌های مطالعات اخیر در این حوزه از جمله مطالعات لین و همکاران (۲۰۲۱) و ژانگ و همکاران (۲۰۲۰) مبنی بر افزایش کارایی مدل‌های یادگیری عمیق با استفاده از الگوریتم‌های تجزیه سیگنال را تایید می‌کند. بر همین اساس، به فعالین بازارهای مالی و بازارهای رمز ارزها پیشنهاد می‌گردد علاوه بر استفاده از مدل‌های یادگیری عمیق به عنوان ابزاری کارا در پیش‌بینی‌ها، به منظور افزایش کارایی و دقت این مدل‌ها، الگوریتم‌های تجزیه سیگنال را مورد توجه قرار دهند. همچنین به محققین حوزه مالی پیشنهاد می‌گردد در تحقیقات آتی، تاثیر کاربرد سایر الگوریتم‌های تجزیه سیگنال در افزایش کارایی مدل پیشنهادی را مورد بررسی قرار دهند.

## ۶- فهرست منابع

- ۱) امامی، کریم و امام وردی، قدرت الله. (۱۳۸۸). بررسی امکان پیش‌بینی شاخص قیمت سهام در بازار سرمایه ایران و مقایسه توان پیش‌بینی مدل‌های خطی و غیرخطی. اقتصاد مالی، ۳(۷)، ۵۶-۸۳.
  - ۲) باباجانی، جعفر، تقوا، محمدرضا، بولو، قاسم، عبدالهی، محسن. (۱۳۹۸). مقاله پژوهشی: پیش‌بینی قیمت سهام در بورس تهران با استفاده از شبکه عصبی بازگشتی بهینه شده با الگوریتم کلونی زنبور عسل مصنوعی. راهبرد مدیریت مالی ۷(۲)، ۲۲۸-۱۹۵.
  - ۳) باغستانی، علی اکبر، یزدانی، سعید و احمدیان، مجید. (۱۳۹۴). کاربرد رهیافت شبکه عصبی در پیش‌بینی قیمت کنجاله سویا در بورس کالای ایران. اقتصاد مالی، ۹(۳۳)، ۱-۱۴.
  - ۴) بختیاران، محمد جواد، ذوالفقاری، مهدی. (۱۴۰۰). طراحی مدلی جهت پیش‌بینی بازده بیت‌کوین (با تأکید بر مدل‌های ترکیبی شبکه عصبی کانولوشنی و بازگشتی و مدل‌های با حافظه بلندمدت). مهندسی مالی و مدیریت اوراق بهادار. ۱۲(۴۷)، ۱۶۱-۱۸۷.
  - ۵) بشیری، میثم، پاریاب، سیدحسین. (۱۳۹۹). پیش‌بینی قیمت بیت‌کوین با استفاده از الگوریتم‌های یادگیری ماشین، اقتصاد کاربردی، ۱۰(۳۴)، ۱-۱۳.
  - ۶) صالحی فر، محمد. (۱۳۹۸). بررسی رفتار بازده و ریسک بیت‌کوین در مقایسه با بازارهای طلا، ارز و بورس با رویکرد مدل‌های GJR-GARCH و گارچ آستانه. مهندسی مالی و مدیریت اوراق بهادار، ۱۰(۴۰)، ۱۶۸-۱۵۲.
  - ۷) کاویانی، میثم، فخرحسینی، سید فخرالدین، دستیار، فاطمه. (۱۳۹۹). مروری بر اهمیت و چرایی پیش‌بینی بازده سهام: با تأکید بر متغیرهای کلان اقتصادی. حسابداری و منافع اجتماعی، ۱۰(۲)، ۱۱۳-۱۳۱.
  - ۸) محمدشریفی، ابوصالح، خلیلی دامغانی، کاوه، عبدی، فرشید، سردار، سهیلا. (۱۴۰۰). پیش‌بینی قیمت بیت‌کوین با استفاده از مدل ترکیبی ARIMA و یادگیری عمیق. مطالعات مدیریت صنعتی، ۱۹(۶۱)، ۱۴۶-۱۲۵.
  - ۹) مریم دولو، تکتیم حیدری (۱۳۹۶). پیش‌بینی شاخص سهام با استفاده از ترکیب شبکه عصبی مصنوعی و مدل‌های فرا‌ابتکاری جستجوی هارمونی و الگوریتم ژنتیک، نشریه اقتصاد مالی، ۱۱(۴۰)، ۱-۲۳.
- 1) Babajani, J., Taghva, M., Blue, G., Abdollahi, M. (2019). Forecasting Stock Prices in Tehran Stock Exchange Using Recurrent Neural Network Optimized by Artificial Bee Colony Algorithm. Financial Management Strategy, 7(2), 195-228. (in Persian)
  - 2) Bonneau, J., Miller, A., Clark, J., Narayanan, A., Kroll, J. A., & Felten, E. W. (2015). Sok: Research perspectives and challenges for bitcoin and cryptocurrencies, In 2015 IEEE Symposium on Security and Privacy (pp. 104-121). IEEE.
  - 3) Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. P., Nobrega, J. P., & Oliveira, A. L. I. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. Expert Systems with Applications, 55, 194-211.
  - 4) Karakoyun, E. S., & Cibikdiken, A. O. (2018). Comparison of arima time series model and lstm deep learning algorithm for bitcoin price forecasting, In The 13th multidisciplinary academic conference in prague 2018 (the 13th mac 2018) (pp. 171-180).

- 5) kaviani, M., Fakhrehosseini, S., dastyar, F. (2020). An Overview of the Importance and Why the Stock Return Prediction, with Emphasis on Macroeconomic Variables. *Journal of Accounting and Social Interests*, 10(2), 113-131. (in Persian)
- 6) Lin, Y., Yan, Y., Xu, J., Liao, Y., & Ma, F. (2021). Forecasting stock index price using the CEEMDAN-LSTM model. *The North American Journal of Economics and Finance*, 57, 101421.
- 7) Patrick Jaquart, David Dann, Christof Weinhardt (2021). Short-term bitcoin market prediction via machine learning, *The Journal of Finance and Data Science*, Volume 7, 45-66.
- 8) Sarafraz, S., Sefati, F. and Ghiasvand, A. (2016). Predicting stock prices with hybrid market indices using a fuzzy neural model. *International Conference on Modern Research in Management, Economics and Accounting*. (in Persian)
- 9) Shengao Zhang, Mengze Li, Chunxiao Yan (2022). The Empirical Analysis of Bitcoin Price Prediction Based on Deep Learning Integration Method, *Computational Intelligence and Neuroscience*, vol. 2022, Article ID 1265837, 9 pages.
- 10) Sin, E., & Wang, L. (2017). "Bitcoin price prediction using ensembles of neural networks", In 2017 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD) (pp. 666-671). IEEE.
- 11) Yamak, P. T., Yujian, L., & Gadosey, P. K. (2019). A Comparison between ARIMA, LSTM, and GRU for Time Series Forecasting, In *Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence* (pp. 49-55).
- 12) Yan, B., & Aasma, M. (2020). A novel deep learning framework: Prediction and analysis of financial time series using CEEMD and LSTM. *Expert systems with applications*, 159, 113609.
- 13) Zarei, G., Mohamadiyan, R., Nayeri Hazeri, H., Mashokouh ajirlou, M. (2018). The Comparison of Fuzzy Neural Network Methods with Wavelet Fuzzy Neural Network in Predicting Stock Prices of Banks Accepted in Tehran Stock Exchange. *Financial Management Strategy*, 6(3), 109-138. (in Persian)

**Presenting the Forecasting Model of Bitcoin Return Using the hybrid Method of Deep Learning - Signal Decomposition Algorithm (CEEMD-DL)**

Sakineh Sayadi Nezhad<sup>1</sup>  
Ali Esmailzadeh Maghari<sup>2</sup>  
Mohammad Reza Rostami<sup>3</sup>

Received: 24 / December / 2022 Accepted: 25 / February / 2023

**Abstract**

With the increasing popularity and widespread use of cryptocurrencies, the creation and development of methods for predicting price movements in this field has attracted a lot of attention. In between, recent developments in deep learning (DL) models with structures such as long-short-term memory (LSTM) and convolutional neural network (CNN) have made improvements in the analysis of this type of data. Another approach that can be effective in the analysis of cryptocurrencies time series is the decomposition through algorithms such as complete integrated empirical mode decomposition (CEEMD). Considering the importance of forecasting in the cryptocurrencies field, in this research, by combining deep learning models and complete integrated empirical mode decomposition (CEEMD), The hybrid CEEMD-DL(LSTM) model has been used to forecast the bitcoin return (as the most popular currency). In this regard, the daily data of the total index of the Tehran Stock Exchange was used in the period of 2013/01/01 – 2022/05/28 and the results obtained were compared with the results of competing models based on efficiency measurement criteria. Based on the obtained results, the use of the introduced model (CEEMD-DL(LSTM)) has increased the efficiency and accuracy of bitcoin return forecasting. Accordingly, the use of this model in this field is suggested.

**Keywords:** Deep Learning Models (DL), Complete Integrated Empirical Mode Decomposition (CEEMD), Cryptocurrencies, Long-Short-Term Memory (LSTM), Convolutional Neural Network (CNN).

**JEL Classification:** E37 ,C61 ,C45 ,G18

<sup>1</sup> Department of Finance, Science and Research Unit, Islamic Azad University, Tehran, Iran, email: bsn231@yahoo.com

<sup>2</sup> Accounting Department, Central Tehran Branch, Islamic Azad University, Tehran, Iran (corresponding author) email: alies35091@gmail.com

<sup>3</sup> Department of Management, Alzahra University, Tehran, Iran, email: m.rostami@alzahra.ac.ir

