



فصلنامه راهبرد مدیریت مالی

دانشگاه الزهرا

سال دوازدهم، شماره چهل و چهارم، بهار ۱۴۰۳

صفحات ۲۲۶-۲۱۱



### مقاله پژوهشی

ارایه مدل پیش‌بینی تجزیه سیگنال‌های بازار سرمایه با استفاده از رویکرد

(CEEMD-DL(LSTM))<sup>۱</sup>

سکینه صیادی نژاد<sup>۲</sup>، علی اسماعیل زاده مقری<sup>۳</sup>، محمدرضا رستمی<sup>۴</sup>، احمد یعقوب نژاد<sup>۵</sup>

تاریخ پذیرش: ۱۴۰۱/۱۲/۱۲

تاریخ دریافت: ۱۴۰۱/۰۵/۱۲

### چکیده

ویژگی غیرخطی و نوسانات بالا در سری‌های زمانی مالی، پیش‌بینی قیمت سهام و شاخص‌های مالی را با چالش‌های زیادی مواجه ساخته‌است. با این حال توسعه‌های اخیر در 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 سری‌های زمانی مالی کارا باشد تجزیه سیگنال‌های بازار سرمایه از طریق الگوریتم‌هایی مانند تجزیه مد تجزیه یکپارچه کامل (CEEMD) می‌باشد. با توجه به اهمیت مقوله پیش‌بینی در بازارهای مالی، در این پژوهش با ترکیب مدل‌های یادگیری عمیق و روش تجزیه مد تجزیه یکپارچه کامل (CEEMD)، مدل هیبریدی CEEMD-DL(LSTM) به منظور پیش‌بینی شاخص بورس اوراق بهادار تهران مورد استفاده قرار گرفته‌است. در این راستا از داده‌های روزانه شاخص کل بورس اوراق بهادار تهران در دوره زمانی ۱۳۹۰/۱۲/۰۱ - ۱۴۰۰/۱۲/۰۱ استفاده شده‌است. نتایج بدست آمده با نتایج مدل‌های رقیب بر اساس معیارهای سنجش کارایی مقایسه شد. بر اساس نتایج بدست آمده، مدل معرفی شده (CEEMD-DL(LSTM))، در مقایسه با مدل‌های سنتی در این حوزه از کارایی و دقت پیش‌بینی بالاتری برخوردار است. بر همین اساس کاربرد این مدل در پیش‌بینی‌های مالی پیشنهاد می‌گردد.

**واژگان کلیدی:** مدل‌های یادگیری عمیق (DL)، تجزیه مد تجزیه یکپارچه کامل (CEEMD)، شاخص

بورس اوراق بهادار تهران، حافظه بلندمدت - کوتاه مدت (LSTM)، شبکه عصبی کانولوشنی (CNN).

**طبقه‌بندی موضوعی:** G18, C45, C61, E37

۱. کد DOI مقاله: 10.22051/JFM.2024.41203.2716

۲. دانشجوی دکتری، گروه مدیریت مالی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات دانشگاه آزاد اسلامی، تهران، ایران. Email: bsn231@yahoo.com.

۳. دانشیار، گروه حسابداری، واحد اسلامشهر، دانشگاه آزاد اسلامی، تهران، ایران و استاد مدعو، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. Email: alies35091@gmail.com.

۴. دانشیار، گروه مدیریت، دانشکده علوم اجتماعی و اقتصاد، دانشگاه الزهرا، تهران، ایران و استاد مدعو، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. نویسنده مسئول. Email: m.rostami@alzahra.ac.ir.

۵. دانشیار، گروه حسابداری، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران. Email: yaghoobacc@gmail.com.

## مقدمه

امروزه، با توجه به اهمیت و گسترش روزافزون بازارهای سرمایه در تجهیز و گردآوری سرمایه‌های کوچک فردی به سمت فعالیت‌های تولیدی، شناسایی رفتار سرمایه‌گذاران و متغیرهای تاثیرگذار بر بازده سهام در این بازارها اهمیت زیادی پیدا کرده است. بدون تردید سرمایه‌گذاری در بورس، بخش مهمی از اقتصاد کل کشور را تشکیل می‌دهد و بدون شک بیش‌ترین میزان سرمایه از طریق بازارهای سهام در سرتاسر جهان مبادله می‌شود و اقتصاد ملی به شدت متأثر از عملکرد بازار سهام است. هم‌چنین این بازار هم برای سرمایه‌گذاران حرف‌های و هم برای عموم مردم به عنوان یک ابزار سرمایه‌گذاری در دسترس می‌باشد (صمدی و بیانی، ۱۳۹۰).

از آنجا که سرمایه‌گذاران بالقوه‌ی بازار اوراق بهادار را طیف وسیعی در جامعه تشکیل می‌دهند، فراهم نمودن بستری مناسب برای حضور گسترده‌ی این طیف و جلب اعتماد آن‌ها، تحکیم بازار سرمایه و عمق بخشیدن به این بازار، یکی از اساسی‌ترین ابزارهای توسعه‌ی اقتصادی را به ارمغان خواهد آورد. در این راستا، ارائه جدیدترین ابزارهای علمی جهت تجزیه و تحلیل و پیش‌بینی بازارهای مالی می‌تواند نقش بسزایی در جلب اعتماد و مدیریت ریسک در این بازارها ایفا نماید.

یادگیری ماشینی (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 زیادی 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، گرایش با نام یادگیری عمیق (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 معنی‌داری، خطاهای کوچکتری را در پیش‌بینی نسبت به مدل‌های آماری نشان می‌دهند و دارای سرعت پیش‌بینی بالاتری هستند. با این که یادگیری عمیق در سال‌های ابتدایی توسعه خود قرار دارد، اما روند پمطالعات، پژوهش‌ها و سرمایه‌گذاری‌های شرکت‌های بزرگ در این حوزه، نشان‌دهنده 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 (کاوآنکانتنه و همکاران<sup>۳</sup>، ۲۰۱۶). از طرفی دیگر، در سال‌های اخیر استفاده از روش‌های تجزیه سیگنال به

1. Machine Learning
2. Deep Learning
3. Cavalcante et al.

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.

با توجه به اهمیت مقوله پیش‌بینی در بازارهای مالی، در این پژوهش برای اولین بار در ایران، با ترکیب مدل‌های یادگیری عمیق و روش تجزیه مد تجزیه یکپارچه کامل (CEEMD<sup>۱</sup>)، مدل هیبریدی (CEEMD- DL(LSTM)<sup>۲</sup>) به منظور پیش‌بینی شاخص بورس اوراق بهادار تهران معرفی و مورد استفاده قرار می‌گیرد. در ادامه بر اساس معیارهای سنجش کارایی، تلاش می‌شود کارایی مدل ارائه شده با مدل‌های سنتی در این حوزه مقایسه گردد. انتظار می‌رود با استفاده از مدل CEEMD- DL(LSTM) بتوان کارایی و دقت پیش‌بینی شاخص‌های بازار سهام را افزایش داد.

در این بخش مقدمه ای جهت معرفی و بیان مسئله اصلی پژوهش بیان گردید. در ادامه در بخش ۲ پیشینه داخلی و خارجی موضوع ارائه شده است. در بخش ۳، روش پژوهش و شرح مختصری از مدل‌های مورد استفاده ارائه بیان می‌شود. در بخش ۴، یافته‌های پژوهش و نتایج پیش‌بینی و ارزیابی عملکرد مدل CEEMD- DL(LSTM) ارائه می‌شود و در نهایت در بخش ۵ نتایج بدست آمده مورد بحث قرار می‌گیرد.

## ادبیات پژوهش

### ۱- مبانی پژوهش

داده‌های تاریخی نشان می‌دهد ویژگی‌های پیچیده داده‌های مالی، مانند غیرخطی بودن، عدم قطعیت، نوسان و پویایی، پیش‌بینی آن را دشوار می‌کند و نتایج پیش‌بینی را با عدم قطعیت زیادی مواجه می‌سازد. نظر به اینکه اکثر محققین بر این عقیده هستند که بازارهای مالی از روندی غیرخطی پیروی می‌کند استفاده از مدل‌های غیرخطی و تکنیک‌های پیشرفته، محبوبیت روزافزون و گسترده‌ای در بین متخصصین بازارهای مالی جهت پیش‌بینی متغیرهای مالی پیدا کرده است؛ استفاده از روش‌های هوش مصنوعی از جمله یادگیری عمیق در زمره اینگونه فعالیت‌ها هستند (لین و همکاران<sup>۳</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 پیش‌بینی‌های سری زمانی، ساختار حافظه طولانی کوتاه‌مدت یا (LSTM) است که در واقع یک نوع از شبکه‌های RNN<sup>۴</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

1. Complete Ensemble Empirical Mode Decomposition
2. Complete Ensemble Empirical Mode Decomposition- Deep Learning (Long Short-Term Memory)
3. Lin et al
4. Recurrent Neural Networks

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 میزان پیچیدگی 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 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 تاثیرگذارتری است. حافظه طولانی کوتاه‌مدت 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>1</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. بنابراین می‌تواند اینگونه وابستگی‌های بلندمدت احتمالی را دریافت و حفظ کند.

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 قایل 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 جمله این روش‌ها روش جدید تجزیه مد تجربی یکپارچه کامل (CEEMD) است که در روند تجزیه‌سازی 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 می‌شود (ژانگ و همکاران<sup>2</sup>، ۲۰۲۰).

### پیشینه پژوهش

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 زیادی

1. Recurrent Neural Networks  
2. Zhang et al

در این زمینه انجام نشده است و مطالعات داخلی به استفاده از شبکه‌های عصبی محدود شده است. در این بخش به تعدادی از مطالعات داخلی و خارجی در این حوزه اشاره می‌شود.

باباجانی و همکاران (۱۳۹۸) در پژوهشی 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 پژوهش 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 پژوهش نشان می‌دهد که استفاده از شبکه عصبی بهینه‌شده با الگوریتم کلونی زنبورعسل مصنوعی، دقت قابل ملاحظه‌ای در مقایسه با سایر روش‌های پیش‌بینی دارد.

زارعی و همکاران (۱۳۹۷) در پژوهش خود با عنوان «مقایسه روش‌های شبکه عصبی فازی با شبکه عصبی موجک فازی در پیش‌بینی قیمت سهام بانک‌های پذیرفته‌شده در بورس اوراق بهادار تهران»، از سیستم منطق فازی به همراه سیستم شبکه عصبی چندلایه با ساختار بهینه‌سازی پس انتشار خطا و ماکزیمم همپوشانی تبدیل موجک گسسته برای متغیرهای نرخ ارز، نفت اوپک، طلا، شاخص کل سهام و همچنین حجم معاملات برای پیش‌بینی قیمت سهام استفاده کردند. نتایج این پژوهش در دوره زمانی ۱۳۹۰-۱۳۹۵ حاکی از قابلیت اطمینان بالاتر شبکه عصبی موجک فازی نسبت به شبکه عصبی فازی می‌باشد.

لین و همکاران (۲۰۲۱) در پژوهش خود تلاش کردند 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. در این پژوهش از داده‌های شاخص سی‌اس‌آی ۳۰۰ (CSI300) و اس‌اند پی ۵۰۰ (S&P 500) در دوره زمانی ۲۰۱۹ - ۲۰۰۹ استفاده شده است 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. لیو<sup>۱</sup> (۲۰۱۹) در پژوهشی با استفاده از الگوریتم‌های یادگیری عمیق به پیش‌بینی نوسانات بازدهی شاخص اس‌اند پی ۵۰۰ (S&P 500) در دوره زمانی ۲۰۱۴-۲۰۰۰ پرداخت. در این پژوهش عملکرد مدل‌های یادگیری عمیق و مدل‌های واریانس ناهمسانی شرطی خودرگرسیون تعمیم یافته (GARCH) مقایسه گردید. نتایج این پژوهش برتری مدل‌های یادگیری عمیق در پیش‌بینی نوسانات بازدهی شاخص اس‌اند پی ۵۰۰ را نشان می‌دهد.

تپیریسیتی و ابهینا<sup>۲</sup> (۲۰۱۸) با استفاده از الگوریتم‌های یادگیری عمیق، به پیش‌بینی قیمت سهام بازارهای مالی جهانی در دوره زمانی ۲۰۱۷-۱۹۵۰ پرداختند و در نهایت، با استفاده از ترکیب الگوریتم‌های

1. Liu  
2. Tipirisetty, Abhinav

یادگیری عمیق و تحلیل اخبار از منابع اینترنتی مدلی ترکیبی به منظور پیش‌بینی قیمت سهام پیشنهاد نمودند.

پارک و همکاران<sup>۱</sup> (۲۰۱۷) مدل‌های یادگیری عمیق را با سه روش استخراج ویژگی نظارت نشده (PCA)، رمزنگار خودکار و ماشین بولتزن محدود - برای پیش‌بینی رفتار بازار در آینده ترکیب کرد. نتایج این پژوهش با استفاده از داده‌ها روزانه در دوره زمانی ۲۰۱۴-۲۰۱۰ نشان می‌دهد که استفاده از روش‌های یادگیری عمیق برای پیش‌بینی بازار مالی تا حدی عملکرد پیش‌بینی را افزایش می‌دهد اما، برای دستیابی به نتایج دقیق‌تر باید تعدیلات بیشتری در این رویکرد اعمال نمود.

فیشر و کراوس<sup>۲</sup> (۲۰۱۸) از شبکه LSTM برای پیش‌بینی جهش‌های قیمتی سهام‌های تشکیل دهنده S&P 500 در دوره زمانی ۱۹۹۲-۲۰۱۵ استفاده کردند. نتایج این پژوهش نشان داد که شبکه‌های LSTM عملکرد بهتری نسبت به مدل‌های طبقه‌بندی بدون حافظه (برای مثال جنگل تصادفی (RAF) و رگرسیون لجستیک (LOG)) دارد.

### ۳. روش پژوهش

روش پژوهش حاضر از لحاظ هدف کاربردی و از لحاظ ماهیت و روش علی است. همچنین از نظر ویژگی و جهت داده‌ها پس رویدادی و از طریق اطلاعات گذشته م باشد. در پژوهش حاضر برای جمع‌آوری منابع نظری از روش کتابخانه‌ای و داده‌های مورد نیاز با مراجعه به سایت بورس اوراق بهادار جمع‌آوری شده‌اند. در این پژوهش از داده‌های روزانه شاخص کل بورس اوراق بهادار تهران (به عنوان نماینده پرتفوی بازار) در دوره زمانی ۱۳۹۰/۱۲/۰۱ - ۱۴۰۰/۱۲/۰۱ استفاده شده است.

#### ۳-۱ مدل پژوهش

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، گیت خروجی و گیت فراموشی 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.

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

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

1. Park et al.  
2. Fischer & Krauss

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

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

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

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،  $\sigma_g$  تابع سیگموئید<sup>۱</sup>،  $\sigma_h$  تابع تانژانت هایپربولیک<sup>۲</sup>،  $W$ ،  $U$ : ماتریس‌های وزن که باید آموزش داده شده و برازش شوند و  $b$  پارامترهای بردار بایاس<sup>۳</sup> هستند.

## ۲- مدل CEEMD-DL(LSTM)


روش تجزیه مد تجربی (EMD<sup>۴</sup>) روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرآیندی تحت عنوان غربال کردن صورت می‌گیرد. طی این فرایند سیگنال اصلی به تعدادی مولفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD طبق رابطه (۶) سیگنال اصلی  $x(n)$  را به تعدادی مد ذاتی (IMF) تجزیه می‌کند.

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

که  $r_n(x)$  همان مولفه باقیمانده، بعد از  $n$  تعداد IMFs 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 سیگنال‌ها، در برخی موارد به علت اختلاط مدها؛ توزیع حوزه زمان-فرکانس دچار انقطاع می‌شود و عملکرد EMD دچار نقض می‌گردد (چون میانگین IMF‌ها حالتی نامشخص به خود می‌گیرد). جهت رفع این ایراد، وو و هوانگ (۲۰۰۴) روشی متفاوت با عنوان روش تجزیه مد تجربی یکپارچه کامل (CEEMD) ارائه گردید. در روند تجربه سازی این روش، حجم محدودی از نویز سفید وارد سیگنال اصلی می‌شود. 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 به صورت دوتایی (یکی مثبت و دیگری منفی) به داده اصلی اضافه

1. Sigmoid function
2. Hyperbolic functions
3. Bias
4. Empirical Mode Decomposition

می‌شود تا دو سری IMF مجموع ساخته شود. بنابراین ترکیبی متشکل از داده اصلی و نوفه سفید اضافه شده ایجاد می‌شود که مجموع IMFها برابر سیگنال 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 پژوهش 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)

### ۳- معیارهای ارزیابی

برای ارزیابی کارایی روش‌های پیش‌بینی سری زمانی شاخص بورس اوراق بهادار تهران، از سه معیار اصلی استفاده می‌شود:

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

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

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

این معیارها به صورت روابط زیر تعریف می‌گردند:

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

1. symmetric mean absolute percentage error (SMAPE)
2. mean absolute percentage error (MAPE)
3. root mean square error (RMSE)




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

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

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

### نتایج برآورد مدل‌های پژوهش

در این پژوهش تلاش می‌شود که مدل نوین و هیبریدی CEEMD-DL(LSTM) به منظور پیش‌بینی شاخص بورس اوراق بهادار تهران معرفی و مورد استفاده قرار گیرد. در این راستا از داده‌های روزانه شاخص کل بورس اوراق بهادار تهران (TEPIX) در دوره زمانی ۱۳۹۰/۱۲/۰۱ - ۱۴۰۰/۱۲/۰۱ استفاده شده‌است. در نمودار (۱) نمایی کلی از شاخص بورس اوراق بهادار تهران در دوره مورد بررسی ارائه شده‌است.




نمودار ۱. روند شاخص کل بورس اوراق بهادار تهران

#### ۱- برآورد مدل‌های یادگیری عمیق بدون تجزیه سیگنال

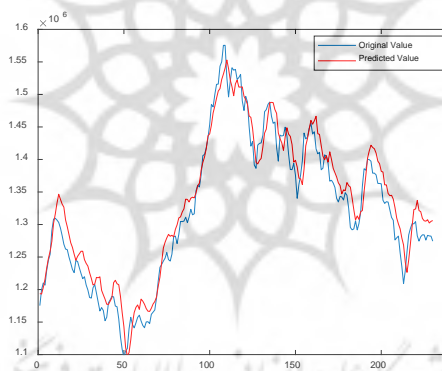
در این بخش نتایج برآورد مدل‌های یادگیری عمیق LSTM و CNN به عنوان دو مدل رقیب و سنتی مورد استفاده در پیش‌بینی‌های سری‌های زمانی مالی ارائه می‌گردد در ادامه نتایج این مدل‌ها با مدل اصلی پژوهش بر اساس معیارهای سنجش کارایی مقایسه می‌شود. بهینه‌سازی فرایند یادگیری در این مدل‌ها بر اساس حداقل‌سازی RMSE و تابع زیان انجام شده‌است.

نمودار (۲) و (۳) به ترتیب پیش‌بینی شاخص بورس اوراق بهادار تهران به وسیله مدل یادگیری عمیق در قالب ساختار LSTM و CNN را در دوره آزمون (۲۴۰ مشاهده نهایی) نشان می‌دهد. بر اساس نمودارهای ارائه شده در این بخش به نظر می‌رسد مدل یادگیری عمیق بر اساس ساختار LSTM کارایی و

دقت بالاتری نسبت به مدل CNN دارد که می‌توان آن را ناشی از ویژگی‌های ارائه شده در بخش‌های قبلی دانست با این حال کارایی این مدل‌ها می‌بایستی در قالب معیارهای سنجش کارایی مورد بررسی قرار گیرد.



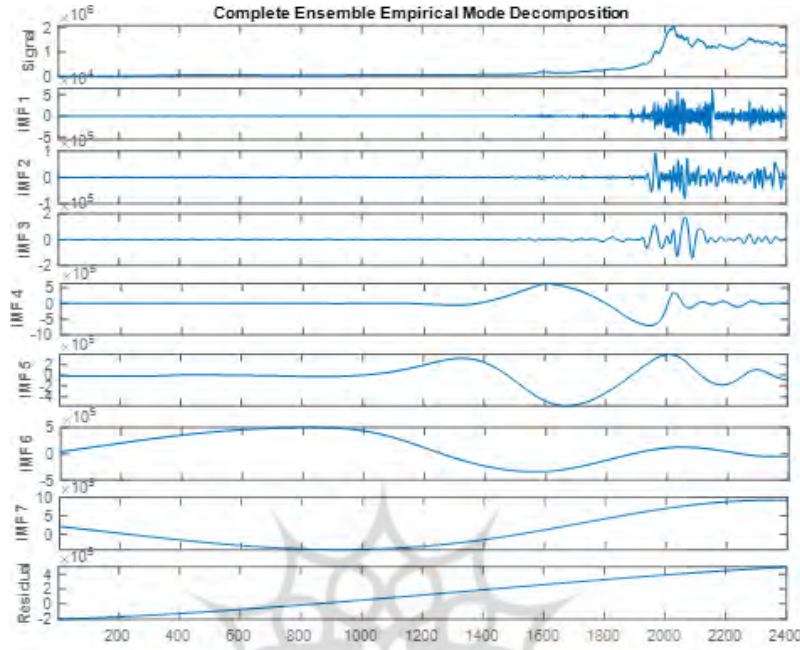
نمودار ۲. پیش‌بینی شاخص بورس اوراق بهادار تهران، مدل یادگیری عمیق (ساختار LSTM)



نمودار ۳. پیش‌بینی شاخص بورس اوراق بهادار تهران، مدل یادگیری عمیق (ساختار CNN)

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

در این بخش و در روند تجزیه سیگنال، داده‌های شاخص کل بورس با استفاده از الگوریتم CEEMD به مولفه‌ها مختلف با بسامدهای مختلف تجزیه می‌شود. به بیان دیگر سری زمانی شاخص کل بورس اوراق بهادار تهران 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 کمتر می‌باشد. در نمودار (۴) تجزیه سیگنال با استفاده از الگوریتم CEEMD به همراه سری زمانی اصلی شاخص بورس اوراق بهادار ارائه شده است.



نمودار ۴. تجزیه سیگنال با استفاده از الگوریتم CEEMD

پس از تجزیه سری اصلی شاخص بورس اوراق بهادار تهران به طیف های بسامدی مختلف با استفاده از الگوریتم CEEMD، قبل از فرایند یادگیری لازم است داده های مورد استفاده نرمال شوند. به این منظور از رابطه (۱۰) استفاده می شود.

$$X_{in} = \frac{x_i(t) - \mu x_i(t)}{\sigma x_i(t)} \quad (10)$$


جایی که  $x_i(t)$  نشان دهنده آامین داده از IMF،  $\mu x_i(t)$  میانگین IMF،  $\sigma x_i(t)$  انحراف معیار و  $X_{in}(t)$  داده های نرمال شده می باشند. لازم به ذکر است می توان با استفاده از معکوس رابطه (۱۰) به داده های اصلی را بدست آورد. جدول (۱) بیانگر تنظیمات های پارامترهای مدل است که بر اساس برآورد چندین مدل و انتخاب مدل با بالاترین کارایی انجام شده است.

#### جدول ۱. تنظیمات های پارامترهای مدل LSTM

|                                      |                     |
|--------------------------------------|---------------------|
| Number of hidden units in LSTM layer | 370                 |
| LSTM layer activation function       | Tanh                |
| Initial Learn Rate                   | 0.005               |
| Optimizer                            | Adam                |
| Loss function                        | Mean_Absolute_Error |
| Epochs                               | 400                 |
| Iteration per Epoch                  | 8                   |
| Iteration                            | 4800                |

مأخذ: محاسبات پژوهش

در ادامه و بر اساس متدولوژی ارائه شده در بخش ۳، هفت تابع ذاتی استخراج شده در مرحله قبل بر اساس مدل یادگیری عمیق با ساختار لایه های (LSTM) و تنظیمات جدول (۱) در فرایند آموزش قرار می‌گیرند و در ادامه با استفاده از فرایند تجمیع سازی نهایی، شاخص بورس اوراق بهادار تهران پیش‌بینی گردید. لازم به ذکر است در مرحله اجرای مدل داده‌های پژوهش ابتدا به دو بخش آموزش و آزمون (۹۰٪ و ۱۰٪) تقسیم گردید همچنین ۲۰٪ (۱۶٪ کل داده‌ها) از دوره آموزش نیز به هدف اعتبار سنجی مدل تخصیص داده شد. نمودار (۵) نتایج پیش‌بینی شاخص بورس اوراق بهادار تهران در دوره آزمون مدل را نشان می‌دهد.



نمودار ۵. پیش‌بینی شاخص بورس اوراق بهادار تهران، مدل CEEMD- DL(LSTM)

### ۳- سنجش کارایی مدل‌های پژوهش

در ادامه و به منظور بررسی کارایی مدل نهایی پژوهش، از معیارهای سنجش کارایی استفاده می‌شود. در این پژوهش از سه معیار میانگین درصد قدمطلق 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 پژوهش 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 این جدول نشان‌دهنده تاثیر مثبت استفاده از الگوریتم‌های تجزیه سیگنال در افزایش کارایی مدل‌های یادگیری عمیق می‌باشد.

### جدول ۲. نتایج معیارهای سنجش کارایی

|                 |          |          |             |
|-----------------|----------|----------|-------------|
| CEEMD- DL(LSTM) | 1.184269 | 1.181812 | 1223.536958 |
| DL(LSTM)        | 1.458807 | 1.471297 | 1479.580456 |
| DL(CNN)         | 1.720297 | 1.736046 | 1770.9573   |

مأخذ: محاسبات پژوهش

## بحث و نتیجه‌گیری

با توجه به تاثیر بازار سرمایه در تامین مالی و توسعه کشور، یافتن روشی مناسب برای پیش‌بینی بازار سهام از اهمیت ویژه‌ای برخوردار است. شوک‌های ناگهانی بازار و سقوط قیمت‌ها تعداد زیادی از سرمایه‌گذاران را از بازار خارج می‌کند. تخصیص صحیح منابع، موجب افزایش اطمینان سرمایه‌گذاران و کارایی بازار خواهد شد. افزایش ابزارهای مرتبط با شاخص‌های مالی، دامنه فرصت‌های سرمایه‌گذاری جهانی را برای سرمایه‌گذاران گسترش داده است. دو دلیل اصلی برای توسعه ابزارهای پیش‌بینی در بازارهای مالی وجود دارد؛ اول اینکه، آنها ابزارهای موثری را برای سرمایه‌گذاران به منظور محافظت از ریسک‌های بالقوه بازار فراهم می‌آورند و دوماً، فرصت‌های کسب سود جدیدی را برای کسانی که از موقعیت‌های زمانی و مکانی بازار استفاده می‌برند، ایجاد می‌کنند.

اخیراً در حوزه یادگیری ماشینی، گرایش یادگیری عمیق (DL)، در پیش‌بینی‌های مالی، توجه بسیاری را جلب کرده‌است. با این که یادگیری عمیق در سال‌های ابتدایی توسعه خود قرار دارد، اما روند مطالعات، مقالات و سرمایه‌گذاری‌های شرکت‌های بزرگ در این حوزه، نشان‌دهنده 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 (کاوآنکانه 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 پژوهش به منظور افزایش کارایی و دقت پیش‌بینی شاخص‌های بورس اوراق بهادار تهران، مدل هیبریدی یادگیری عمیق مبتنی بر ساختار شبکه‌های عصبی (LSTM) و با استفاده از الگوریتم تجزیه مدل تجربی یکپارچه کامل (CEEMD) ارائه گردید. در ادامه نتایج پیش‌بینی شاخص کل بورس اوراق بهادار تهران بر اساس این مدل ((DL(LSTM)-CEEMD) 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 پژوهش، مدل پیشنهادی ((DL(LSTM)-CEEMD) نسبت به دو مدل رقیب مبتنی بر ساختارهای LSTM و CNN از عملکرد بهتری برخوردار می‌باشد. نتایج این پژوهش، 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. این نتایج نشان‌دهنده اهمیت معیارهای مبتنی بر فرکانس (یا افق زمانی) در پیش‌بینی‌های سری زمانی مالی می‌باشد. الگوریتم‌های تجزیه سیگنال، ابزارهای قدرتمندی هستند که امکان جداسازی اجزای اطلاعاتی سری‌های زمانی مالی در فرکانس‌های خاص را ایجاد کرده و می‌توانند دقت و کارایی پیش‌بینی‌های مالی را افزایش دهند. بر همین اساس، به محققین در حوزه مالی پیشنهاد می‌گردد علاوه بر واکاوی مدل‌های یادگیری عمیق به عنوان

ابزاری کارا در پیش‌بینی متغیرهای مالی، به منظور افزایش کارایی و دقت این مدل‌ها، الگوریتم‌های تجزیه سیگنال را مورد توجه قرار دهند.

### ملاحظات اخلاقی

حامی مالی: مقاله حامی مالی ندارد.  
مشارکت نویسندگان: تمام نویسندگان در آماده‌سازی مقاله مشارکت داشته‌اند.  
تعارض منافع: بنا بر اظهار نویسندگان در این مقاله هیچ‌گونه تعارض منافی وجود ندارد.  
تعهد کپی‌رایت: طبق تعهد نویسندگان حق کپی‌رایت رعایت شده‌است.



## References

- Arel, I; Rose, D. C; & Karnowski, T. P. (2010). Deep machine learning- new frontier in artificial intelligence research. *IEEE Computational Intelligence Magazine*, 5(4), 13-18.
- 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).
- 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.
- Chong, E. and Han, C. and Park, F.C. (2017) Deep learning networks for stock market analysis and prediction: methodology, data representations, and case studies. *Expert systems with applications*; 83, 187-205.
- Fischer, T; & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
- 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).
- Langkvist, M; Karlsson, L; & Loutfi, A. (2014). A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42, 11-24.
- 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.
- Samadi, S; Bayani, ozra. (2009). Relation between Macroeconomic Variables and General Index in Tehran Stock Exchange. *Economical Modeling*, 2(6), 111-130. (In Persian).
- 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).
- Tipirisetty, Abhinav, "Stock Price Prediction using Deep Learning" (2018). *Master's Projects*. 636.
- W. Long, Z. Lu and L. Cui, (2018). Deep learning-based feature engineering for stock price movement prediction, *Knowledge-Based Systems*, 164, 163-173.
- 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.

Y. Liu, (2019). Novel Volatility Forecasting Using Deep Learning – Long Short-Term Memory Recurrent Neural Networks, *Expert Systems with Applications*, 132, 99-109.

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).

#### COPYRIGHTS



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

