



مقاله پژوهشی

پیش‌بینی قیمت سهام با استفاده از ترکیب الگوریتم‌های یادگیری عمیق (GRU و LSTM, RNN)
و تجزیه فرکانسی^۱

علی نمکی^۲، سعید شیرکوند^۳، یداله صفائی‌پور^۴

تاریخ پذیرش: ۱۴۰۳/۰۹/۰۶

تاریخ دریافت: ۱۴۰۳/۰۱/۲۴

چکیده

غیرخطی بودن و نوسانات بالای سری‌های زمانی مالی، پیش‌بینی قیمت سهام را دشوار کرده است. هرچند با پیشرفت‌های اخیر در حوزه یادگیری عمیق و استفاده از مدل‌های شبکه‌های عصبی مانند LSTM, RNN و GRU، بهبودهای قابل توجهی در تحلیل این نوع داده‌ها به وجود آمده است، اما سیستم‌های مالی پیچیده و پویا به راحتی تحت تأثیر نویز قرار می‌گیرند. وجود نویز در سری‌های زمانی باعث می‌شود که مدل‌های یادگیری عمیق به سختی بتوانند الگوها و ویژگی‌های پنهان سری‌های زمانی را استخراج کنند و در نتیجه، توانایی یادگیری و دقت پیش‌بینی مدل‌های یادگیری عمیق کاهش می‌یابد. تحقیقات نشان داده است که روش تجزیه کامل به مجموعه مؤلفه‌های مود تجری (CEEMD) ممکن است در تجزیه و تحلیل سری‌های زمانی مالی مؤثر باشد. پژوهش حاضر به دنبال طراحی یک مدل براساس تجزیه سری‌های زمانی برای پیش‌بینی یک روز آینده است. در این راستا، این پژوهش در چهار ساختار، مدل CEEMD را با مدل‌های یادگیری عمیق مانند LSTM, RNN و GRU و مدل آماری ARMA ترکیب کرده است. برای ارزیابی مدل‌ها از داده شاخص کل و داده‌های قیمت سهام ۳۴ شرکت فعال تر بورس تهران مربوط به بازه زمانی فروردین ۱۳۹۶ تا فروردین ۱۴۰۱ استفاده شده است. نتایج این پژوهش نشان می‌دهد که تجزیه داده‌های خام می‌تواند فرآیند استخراج ویژگی‌ها و الگوها را برای یادگیری ماشین تسهیل نماید. به علاوه، مدل CEEMD-ARMA-LSTM نسبت به مدل‌های ترکیب نشده دقت پیش‌بینی را ۳ درصد افزایش داده است.

واژگان کلیدی: پیش‌بینی شاخص سهام، یادگیری عمیق، CEEMD، ARMA، LSTM.

طبقه‌بندی موضوعی: C19، C53، C58، C13، G17

۱. doi مقاله: 10.22051/jfm.2025.46888.2917

۲. استادیار، گروه مهندسی مالی، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران. نویسنده مسئول.

Email: alinamaki@ut.ac.ir

۳. دانشیار، گروه مهندسی مالی، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران. Email: shirkavnd@ut.ac.ir

۴. کارشناسی ارشد، گروه مالی گرایش بانکداری، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران.

Email: y.safaeipour@ut.ac.ir

مقدمه

یکی از دغدغه‌های اصلی سرمایه‌گذاران در بازار سرمایه، پیش‌بینی روند بازارهای مالی برای تصمیم‌گیری مناسب و برنامه‌ریزی صحیح برای آینده است. اگرچه پیش‌بینی دقیق بازارها غیرممکن است، اما برخی از محققان با ارائه روش‌ها، ایده‌ها و تحلیل‌های مختلف سعی در رفع این مشکل دارند. با این وجود، برخی از ویژگی‌های داده‌های سری‌های زمانی مالی مانند نامان بودن، غیرخطی بودن و نوسانات بالا، پیش‌بینی سری‌های مالی را دشوار کرده است (پولانکو-مارتینز، ۲۰۱۹). به همین دلیل، محققان به طور مستمر به دنبال یافتن مدل‌های بهتر و دقیق‌تر برای تجزیه و تحلیل داده‌های سری زمانی مالی هستند. بسیاری از مدل‌های پیش‌بینی سهام عمدتاً به عنوان مدل‌های آماری یا یادگیری ماشینی طبقه‌بندی می‌شوند (علی و همکاران، ۲۰۲۰). مدل‌های آماری برای تجزیه و تحلیل سری‌های زمانی دارای یک سری پیش‌فرض‌ها هستند. از جمله این که فرض می‌کنند مولفه‌های آماری سری زمانی در طول زمان ثابت باقی می‌مانند و سری زمانی را خطی در نظر می‌گیرند (مک نالی و همکاران، ۲۰۱۸). از آنجا که سری‌های زمانی مالی غیرخطی هستند، استفاده از این مدل‌ها برای تجزیه و تحلیل سری‌های زمانی مالی با خطای زیادی همراه است. مدل‌های یادگیری عمیق برای تجزیه و تحلیل سری‌های زمانی از پیش‌فرض ثابت بودن مولفه‌های آماری استفاده نمی‌کنند، بنابراین، این مدل‌ها می‌توانند بر محدودیت‌های مدل‌های آماری سنتی برای تجزیه و تحلیل سری‌های زمانی غلبه کنند (گان و همکاران، ۲۰۲۰). اگرچه استفاده از روش‌های یادگیری عمیق در تجزیه و تحلیل داده‌های سری‌های زمانی مالی بسیار مفید بوده است، اما برخی از سری‌های زمانی مالی دارای نوسانات تصادفی بالایی هستند که تحلیل و پیش‌بینی آن‌ها هنوز چالش‌برانگیز است (رضایی و همکاران، ۲۰۲۱). علت این است که برخی از سیستم‌های مالی پیچیده و پویا به راحتی تحت تأثیر نویز قرار می‌گیرند و وجود نویز در سری‌های زمانی باعث می‌شود که مدل‌های یادگیری عمیق به سختی بتوانند الگوها و ویژگی‌های پنهان سری‌های زمانی را استخراج کنند. در نتیجه، توانایی یادگیری و دقت پیش‌بینی مدل‌های یادگیری عمیق کاهش می‌یابد (رضایی و همکاران، ۲۰۲۱).

روش‌های تجزیه

فرکانس مانند تجزیه کامل به مجموعه مؤلفه‌های مود تجربی^۱ (CEEMD) این توانایی را دارند که به عنوان ابزاری مفید در کاهش پیچیدگی سری‌های زمانی عمل کنند (علی و همکاران، ۲۰۲۰). این روش‌ها به راحتی می‌توانند داده‌های با نوسان بالا را به اجزای با فرکانس کوچک‌تر تجزیه کنند (علی و همکاران،

1. non-stationary
2. nonlinearity
3. high volatility
4. Polanco-Martínez
5. Ali et al
6. McNally, Roche & Caton
7. Gan, Wang & Yang
8. Rezaei, Faaljou & Mansourfar
9. Complete Ensemble Empirical Mode Decomposition

۲۰۲۰). روش‌های تجزیه فرکانسی می‌توانند نقش مهمی در تحلیل سری‌های زمانی مالی در کنار مدل‌های یادگیری عمیق ایفا کنند (نیو و همکاران^۱، ۲۰۲۰؛ ال، چن و همکاران^۲، ۲۰۱۹). روش CEEMD پیچیدگی سری‌های زمانی را کاهش می‌دهد (ژوان و همکاران^۳، ۲۰۲۰). ترکیب مدل‌های یادگیری عمیق با روش‌های تجزیه فرکانس نشان می‌دهد که این مدل‌ها قادرند سری‌های زمانی تجزیه‌شده را بهتر از سری‌های زمانی یکپارچه تحلیل کنند (ال وی و همکاران^۴، ۲۰۲۲).

پژوهش حاضر به بررسی افزایش دقت پیش‌بینی بازارهای مالی از طریق طراحی یک ساختار ترکیبی از مدل‌های آماری و یادگیری عمیق پرداخته است. این ساختار از مزایای روش CEEMD برای تجزیه داده‌ها به روندهای با فرکانس‌های کوچک‌تر استفاده می‌کند که پیچیدگی سری‌های زمانی را کاهش داده و استخراج ویژگی‌های انتزاعی و عمیق را تسهیل می‌کند. همچنین، از تست دیکی فولر^۵ (ADF) برای بررسی ثابت بودن داده‌ها و تفکیک سری‌های زمانی ثابت و ناپایدار بهره می‌برد (ال وی و همکاران، ۲۰۲۲). در این پژوهش، از مدل آماری میانگین متحرک خودرگرسیون^۶ (ARMA) برای پیش‌بینی سری‌های زمانی ثابت و از مدل‌های یادگیری عمیق برای پیش‌بینی سری‌های زمانی ناپایدار استفاده شده است. هدف این پژوهش، آزمون فرضیه‌ای است که تجزیه داده‌ها و ترکیب مدل‌های یادگیری عمیق با مدل‌های آماری می‌تواند دقت پیش‌بینی‌ها را افزایش دهد. برای آزمون این فرضیه، چهار ساختار با طراحی‌های متفاوت از مدل‌های یادگیری عمیق بر اساس داده‌های سهام ۳۴ شرکت بورس تهران طی دوره زمانی ۱۳۹۶ تا ۱۴۰۱ مورد استفاده قرار گرفته است.

این پژوهش در هفت بخش تنظیم گردیده است؛ پس از بیان مقدمه پژوهش، پیشینه نظری پژوهش بررسی شده و روش‌شناسی پژوهش در بخش بعدی آمده است. در ادامه ساختار داده‌ها و معیارهای ارزیابی و یافته‌های پژوهش بیان شده و بخش آخر نیز، به بحث نتیجه‌گیری اختصاص یافته است.

مبانی نظریه و مروری بر پیشینه پژوهش

تجزیه و تحلیل نقاط مشاهده شده در سری‌های زمانی مالی، ابزاری مهم برای پیش‌بینی بازارهای مالی است. مدل ARIMA یکی از پرکاربردترین ابزارهای تحلیل سری‌های زمانی برای پیش‌بینی بازارهای مالی است (خاشعی و بیجاری، ۲۰۱۱). این مدل از ترکیب مدل‌های خودرگرسیون^۷ (AR) و میانگین متحرک^۸ (MA) تشکیل شده و فرض می‌کند که پیش‌بینی‌های آینده وابستگی خطی به مقادیر داده‌های فعلی و

1. Niu, Xu & Wang
2. Chen et al
3. Xuan, Yu & Wu
4. LV et al
5. Dickey Fuller
6. Autoregressive Moving Average
7. Autoregressive
8. Moving Average

گذشته دارند. متوسلی و کاشفی (۲۰۰۶) سهام ۴۰ شرکت بورس تهران را برای دوره‌های زمانی ۱۳۸۱ تا ۱۳۸۴ پیش‌بینی کردند و دریافتند که مدل ARIMA عملکرد خوبی دارد.

شبکه‌های عصبی بازگشتی^۱ (RNN) برای تحلیل سری‌های زمانی غیرخطی طراحی شده‌اند. این مدل‌ها قادرند اطلاعات دوره‌های قبلی سری‌های زمانی را حفظ کرده و از آن‌ها در تجزیه و تحلیل دوره‌های فعلی و آینده استفاده کنند (هوکرایتر و اشمیدور^۲، ۱۹۹۷). ژانگ و همکاران^۳ (۲۰۱۹) به مطالعه یادگیری عمیق و تحلیل رفتار پیچیده و نامنظم داده‌های اقتصادی پرداختند و ادعا کردند که شبکه‌های عصبی بازگشتی در درک روند و رفتار سری‌های زمانی عملکرد بهتری دارند. یکی از ایرادهای مدل RNN این است که حافظه زیادی برای به خاطر سپردن اطلاعات ندارند و فقط می‌توانند آخرین اطلاعات استخراج شده از سری زمانی را به خاطر بسپارند. به همین دلیل، شبکه‌های LSTM برای توالی‌های طولانی که نیازمند به خاطر سپردن تمام اطلاعات موجود در توالی کامل هستند، به وجود آمدند (هوکرایتر و اشمیدور، ۱۹۹۷).

نلسون و همکاران^۴ (۲۰۱۷) بیان کردند که مدل LSTM برای پیش‌بینی سری‌های زمانی بسیار مناسب است و نتایج دقیق‌تری نسبت به سایر مدل‌های یادگیری ماشین مانند جنگل‌های تصادفی^۵، پرسپترون چندلایه^۶ و مدل‌های تصادفی ارائه می‌دهد. فیشر و کراوس^۷ (۲۰۱۸) از شبکه LSTM برای پیش‌بینی سهام تشکیل‌دهنده شاخص S&P ۵۰۰ استفاده کردند و نتایج تجربی نشان داد که شبکه‌های LSTM نسبت به مدل‌های بدون حافظه عملکرد بهتری دارند. لیو^۸ (۲۰۱۹) برای پیش‌بینی نوسانات شاخص‌های سهام (S&P ۵۰۰ و AAPL) از مدل LSTM استفاده کرد و دریافت که این مدل در مقایسه با ماشین‌های بردار پشتیبان (SVM) و مدل GARCH عملکرد بهتری دارد. نیکو، منصورفر و باقرزاده (۱۳۹۹) روش‌هایی مانند ANN، SVR، جنگل تصادفی و LSTM را در پیش‌بینی سری‌های زمانی مالی مورد مطالعه قرار دادند و در نهایت LSTM را به عنوان روشی با دقت بالا در پیش‌بینی معرفی کردند. مدل GRU توسعه‌یافته مدل LSTM است که در مقایسه با LSTM دارای متغیرهای کمتری است.

این ویژگی باعث می‌شود GRU کارآمدتر و سریع‌تر از LSTM. (آگاروال و همکاران^۹، ۲۰۱۹). به طور گسترده پذیرفته شده است که بازارهای مالی یک سیستم دینامیکی پیچیده، غیرخطی و غیرثابت دارند (یان و آسما^{۱۰}، ۲۰۲۰) این پیچیدگی و غیرخطی بودن سری‌های زمانی مالی باعث می‌شود

1. Recurrent neural networks
2. Hochreiter & Schmidhuber
3. Zhang et al
4. Nelson et al
5. Random Forest
6. Multilayer perceptron
7. Fischer & Krauss
8. Liu
9. Aggarwal et al
10. Yan & Aasma

که مدل‌های یادگیری عمیق عملکرد مناسبی در تجزیه و تحلیل این سری‌ها نداشته باشند. بنابراین، بهتر است قبل از پیش‌بینی سری‌های زمانی مالی با استفاده از مدل‌های یادگیری عمیق، در مرحله پیش‌پردازش نویززدایی شوند. حسیه^۱ (۲۰۱۱) و و بائو^۲ (۲۰۱۷) برای حذف نویز سری‌های زمانی مالی، تابع تبدیل موجک^۳ (WT) را معرفی کردند. فلاح‌پور و علی‌پور (۲۰۱۴) برای پیش‌بینی شاخص بازار بورس تهران از ترکیب تبدیل موجک و شبکه عصبی استفاده کردند و دریافتند که استفاده از تبدیل موجک برای نویززدایی داده‌های شاخص بورس تهران باعث افزایش دقت پیش‌بینی شبکه عصبی می‌شود.

یکی از مفروضات تابع تبدیل موجک (WT) این است که واریانس داده‌ها در طول سری زمانی ثابت است. از آنجایی که واریانس داده‌های سری‌های زمانی مالی در طول زمان ثابت نیست، استفاده از تابع موجک با خطای زیادی همراه است (سوویچ و سرشیچ^۴، ۲۰۱۲). بنابراین، هوانگ^۵ (۱۹۹۸) برای سری‌های زمانی غیرخطی و غیرثابت، روش تجزیه حالت تجربی^۶ (EMD) را پیشنهاد کرد. این روش سری زمانی را به تعداد محدودی از توابع حالت ذاتی^۷ (IMF) تقسیم می‌کند که هر IMF مؤلفه‌ای با مقیاس مشخص و فرکانس کوچک‌تر از سیگنال اصلی را نشان می‌دهد. وانگ (۲۰۱۷) برای نویززدایی داده‌های قیمت سهام از روش EMD استفاده کرد و دریافت که این روش باعث افزایش دقت پیش‌بینی مدل‌های شبکه‌های عصبی می‌شود.

با این حال، روش EMD یک مشکل عمده دارد: همخوانی مودال^۸ یعنی؛ در یک جزء از مجموعه IMF‌های یک سری زمانی ممکن است یک IMF با چند فرکانس مختلف پیدا شود. برای حل این مشکل، وو و همکاران (۲۰۰۹) روش مجموعه تجزیه حالت تجربی^۹ (EEMD) را که توسعه یافته روش EMD است، پیشنهاد کردند. روش EEMD چندین بار نویز سفید به سیگنال اصلی اضافه می‌کند، سپس چندین بار روش EMD را اجرا کرده و میانگین آن‌ها را به عنوان IMF در نظر می‌گیرد. یه^{۱۰} و همکاران (۲۰۱۰) روش تجزیه یکپارچه تجربی کامل^{۱۱} (CEEMD) را پیشنهاد کردند، روشی که فقط یک جفت سیگنال نویز سفید مخالف را به سیگنال اصلی اضافه کرده و سپس، روش EMD را اجرا می‌کند. یه و همکاران اطمینان حاصل کردند که دقت روش CEEMD با EEMD برابر است. چن و پان^{۱۲} (۲۰۱۶)، جوتیمانی و یاداو^{۱۳} (۲۰۱۹) و نیز،

1. Hsieh
2. Bao
3. Wavelet Transform
4. Sović & Seršić
5. Huang
6. Empirical mode decomposition
7. intrinsic mode functions
8. modal aliasing
9. Ensemble Empirical Mode Decomposition
10. Yeh
11. Complementary Ensemble Empirical Mode Decomposition
12. Chen & Pan
13. Jothimani & Yadav

جین و همکاران^۱ (۲۰۲۰) اثربخشی روش تجزیه داده‌ها برای افزایش دقت پیش‌بینی مدل‌های یادگیری عمیق عمیق را تأیید کردند و دریافتند که روش CEEMD نسبت به روش EMD عملکرد بهتری دارد.

روش‌شناسی پژوهش

این پژوهش به دنبال پیش‌بینی شاخص کل بورس تهران و قیمت سهام برای روز آینده است. به این منظور، مدل‌های ARMA، RNN، LSTM، GRU و CEEMD بر اساس تئوری‌های مبانی نظری طی چهار مرحله که در هر کدام از مراحل ساختاری متفاوتی دارند، ترکیب می‌شوند. از آنجا که مدل‌های یادگیری عمیق دارای پارامترهای مختلفی هستند که باید هوشمندانه انتخاب شوند، در مرحله اول ساختار مدل‌های یادگیری عمیق طراحی می‌شود. تعداد لایه‌های مخفی یکی از پارامترهای مهم در مدل‌های یادگیری عمیق است که عمل تجزیه داده‌ها را انجام می‌دهد. در این مرحله، مدل‌های یادگیری عمیق بر اساس تعداد لایه‌های مخفی طراحی می‌شوند تا عملکرد آن‌ها بر دقت پیش‌بینی ارزیابی شود. مرحله دوم برای ارزیابی عملکرد تجزیه داده‌ها بر اساس مدل CEEMD طراحی شده است. در این مرحله، مدل CEEMD با مدل‌های یادگیری عمیق که در مرحله اول طراحی شده‌اند، ترکیب می‌شود.

این پژوهش به دنبال پیش‌بینی شاخص کل بورس تهران و قیمت سهام برای روز آینده است. به این منظور مدل‌ها ARMA، RNN، LSTM، GRU و CEEMD بر اساس تئوری‌های مبانی نظری طی چهار مرحله ترکیب می‌شوند که در هر کدام از مراحل ساختاری متفاوت دارند. از آنجا که مدل‌های یادگیری عمیق دارای پارامترهای مختلفی هستند که بایستی هوشمندانه انتخاب شوند در مرحله اول ساختار مدل‌های یادگیری عمیق طراحی می‌شوند. تعداد لایه‌های مخفی، یکی از پارامترهای مهم در مدل‌های یادگیری عمیق است که عمل تجزیه داده‌ها را انجام می‌دهد. در ساختار مرحله اول به منظور ارزیابی عملکرد لایه‌های مخفی بر دقت پیش‌بینی مدل‌های یادگیری عمیق، مدل‌های یادگیری عمیق بر اساس تعداد لایه‌های مخفی طراحی می‌شود. در مرحله سوم، مدل ARMA که یک مدل آماری برای پیش‌بینی داده‌های خطی است، با مدل‌های یادگیری عمیقی که ساختار آن‌ها در مرحله اول طراحی شده‌اند، ترکیب می‌شود. این ترکیب بر اساس الگوریتمی است که جی پی ژانگ^۲ در پژوهش خود استفاده کرده است. در مرحله چهارم، مدل ARMA و مدل CEEMD با هم به مدل‌های یادگیری عمیق ترکیب می‌شوند و مدل نهایی ساخته می‌شود.

ساختار مرحله اول

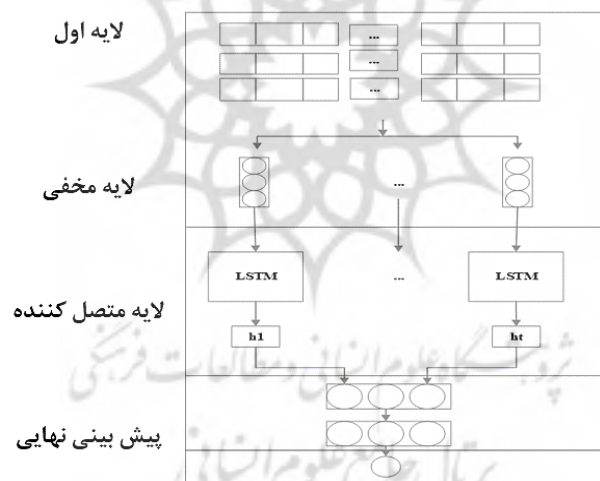
مدل‌های یادگیری عمیق دارای پارامترهای مختلفی هستند که باید به‌طور هوشمندانه انتخاب شوند تا به نتایج مطلوب دست یابند. این پارامترها شامل بهینه‌ساز^۳ (چوی^۴ و همکاران، ۲۰۱۹)، میزان یادگیری

1. Jin, Yang & Liu
2. Zhang
3. Optimization
4. Choi



(یو^۱ و همکاران، ۲۰۱۹)، تعداد دوره‌ها تعداد دوره (سینها و همکاران، ۲۰۱۰)، اندازه دسته دسته^۳ (مستر و لوشی^۴، ۲۰۱۸)، و تعداد لایه‌های مخفی^۵ (شفیع^۶، ۲۰۰۶) و غیره می‌باشند. مرحله اول به طراحی ساختار مدل‌های RNN، LSTM و GRU اختصاص دارد. به منظور انتخاب بهینه پارامترهای مدل‌های یادگیری عمیق، این پارامترها در چهار لایه به شرح زیر بررسی می‌شوند:

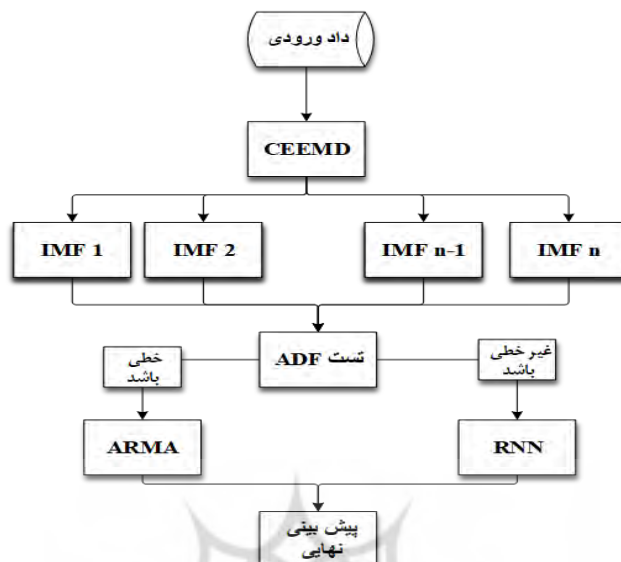
لایه ورودی: با توجه به اینکه این پژوهش از داده‌های معاملاتی ۳۰ روز گذشته برای پیش‌بینی تغییرات قیمت سهام در روز (T+1) استفاده می‌کند، ورودی لایه اول شامل داده‌های ۳۰ روز گذشته است. لایه دوم: که به آن لایه مخفی نیز گفته می‌شود، جایی است که پردازش‌ها و محاسبات میانی انجام می‌شود. در واقع، لایه مخفی به استخراج الگوهای پنهان در داده‌ها می‌پردازد. بنابراین، انتخاب تعداد لایه‌های مخفی تأثیر بسزایی بر دقت پیش‌بینی دارد. در ساختار اولیه، از یک تا چهار لایه مخفی برای استخراج الگوها و رفتارهای پیچیده و طولانی‌مدت سری‌های زمانی در مدل‌های یادگیری عمیق استفاده شده است. لایه سوم یا لایه اتصال کامل: در این مرحله، ویژگی‌هایی که در مراحل قبلی استخراج شده‌اند، به یک بردار یک‌بعدی تبدیل می‌شوند. لایه سوم یا اتصال کامل: در این مرحله، ویژگی‌هایی که در طی مراحل قبلی استخراج شده‌اند به یک بردار یک‌بعدی تبدیل می‌شوند. لایه چهارم یا لایه پیش‌بینی نهایی: این لایه خروجی نهایی شبکه یادگیری عمیق را تولید می‌کند.



نمودار ۱. ساختار مدل LSTM که بر اساس ساختار مرحله اول طراحی شده است

منبع: یافته‌های پژوهش

1. You
2. epochs
3. Batch Size
4. Masters & Luschi
5. Hidden layer
6. Shafi



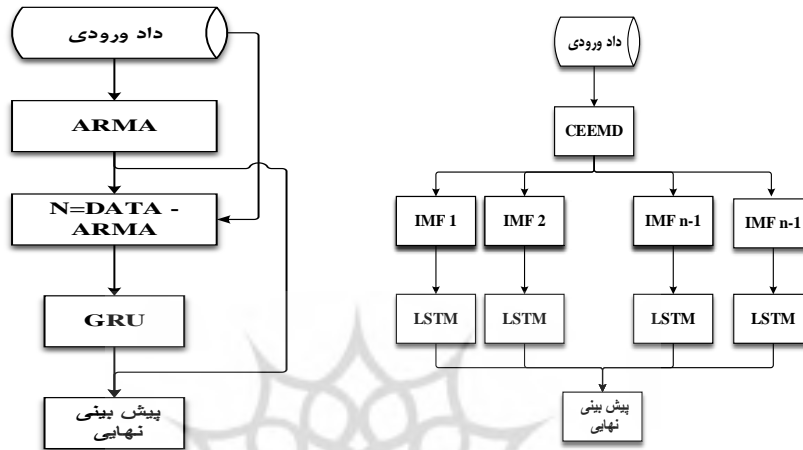
نمودار ۲. ساختار مدل CEEMD-ARMA-RNN که براساس ساختار مرحله چهارم طراحی شده است
منبع: یافته‌های پژوهش

ساختار مرحله دوم

در مرحله دوم مدل CEEMD با یکی از مدل‌های RNN، LSTM و GRU ترکیب می‌شود. بنابراین مرحله دوم شامل سه مدل CEEMD-RNN، CEEMD-LSTM و CEEMD-GRU می‌باشد. هر کدام از این مدل‌ها در سه مرحله ساخته می‌شوند: مرحله ۱: ابتدا از مدل CEEMD برای تجزیه سری‌های زمانی مالی و حذف نویز استفاده می‌شود، مدل CEEMD سری زمانی را به چندین IMF با فرکانس‌های کوچک‌تر تقسیم می‌کند. مرحله ۲: هر یک از IMF که توسط مدل CEEMD برای سری زمانی مورد نظر تولید شده، خود یک سری زمانی با فرکانس کوچک‌تر می‌باشد و برای پیش‌بینی مجموع IMF‌های سری زمانی سهم مورد نظر، از یکی از مدل‌های RNN، LSTM یا GRU سهم استفاده می‌شود. مرحله ۳: پیش‌بینی نهایی برای سهم مورد نظر از جمع پیش‌بینی‌های هر یک از مجموعه IMF‌های آن سهم بدست می‌آید. نمودار ۳ ساختار مدل CEEMD-LSTM که بر اساس مرحله دوم طراحی شده است را نشان می‌دهد.

در مرحله دوم، مدل CEEMD با یکی از مدل‌های RNN، LSTM و GRU ترکیب می‌شود. بنابراین، مرحله دوم شامل سه مدل CEEMD-RNN، CEEMD-LSTM و CEEMD-GRU است. هر کدام از این مدل‌ها در سه مرحله ساخته می‌شوند: ابتدا از مدل CEEMD برای تجزیه سری‌های زمانی مالی و حذف نویز استفاده می‌شود، مدل CEEMD سری زمانی را به چندین IMF با فرکانس‌های کوچک‌تر تقسیم می‌کند. هر یک از IMF که توسط مدل CEEMD برای سری زمانی مورد نظر تولید شده، خود یک سری زمانی با فرکانس کوچک‌تر است. برای پیش‌بینی مجموع IMF‌های سری زمانی سهم مورد نظر، از یکی از

مدل‌های RNN، LSTM یا GRU استفاده می‌شود. پیش‌بینی نهایی برای سهم مورد نظر از جمع پیش‌بینی‌های هر یک از مجموعه IMF های آن سهم به دست می‌آید. نمودار ۳ ساختار مدل CEEMD-LSTM که بر اساس مرحله دوم طراحی شده است را نشان می‌دهد.



نمودار ۴. ساختار مدل ARMA-GRU بر اساس مرحله سوم
منبع: یافته‌های پژوهش

نمودار ۳. ساختار مدل CEEMD-LSTM بر اساس مرحله دوم
منبع: یافته‌های پژوهش

ساختار مرحله سوم

در مرحله سوم، مدل ARMA با یکی از مدل‌های RNN، LSTM و GRU ترکیب می‌شود. بنابراین، مرحله سوم شامل سه مدل ARMA-RNN، ARMA-LSTM و ARMA-GRU است. طبق مبانی نظری، سری‌های زمانی از دو بخش خطی و غیرخطی تشکیل شده‌اند (ژانگ، ۲۰۰۳). بنابراین، مجموعه داده‌های سری زمانی را می‌توان به صورت رابطه ۱ نشان داد:

مرحله سوم مدل ARMA با یکی از مدل‌های RNN، LSTM و GRU ترکیب می‌شود. بنابراین مرحله سوم شامل سه مدل ARMA-RNN، ARMA-LSTM و ARMA-GRU می‌باشد. طبق مبانی نظری سری زمانی از دو بخش‌های خطی و غیرخطی تشکیل شده‌اند (ژانگ ۲۰۰۳). بنابراین، مجموعه داده‌های سری زمانی را می‌توان به صورت رابطه ۱ نشان داد:

$$x_t = L + N_t + \varepsilon_t \quad (1)$$

در رابطه ۱، L داده‌های خطی و N_t داده‌های غیرخطی را در زمان t نشان می‌دهند و ε مقدار خطای احتمالی را مشخص می‌کند.

مرحله سوم برای تجزیه سری‌های زمانی بر اساس بخش‌های خطی و غیرخطی طراحی شده است. این مرحله از سه بخش تشکیل شده است: در بخش اول، به منظور کشف روابط خطی سری زمانی مورد نظر نظر از مدل ARMA استفاده می‌شود. مطابق رابطه ۱، جزء خطی سری زمانی از پیش‌بینی سری مورد نظر توسط مدل ARMA به دست می‌آید و باقیمانده حاصل، یعنی تفاوت میان داده‌های واقعی و مقدار پیش‌بینی شده توسط مدل ARMA، به عنوان جزء غیرخطی و خطا در نظر گرفته می‌شود. به عبارت دیگر، مدل ARMA فقط می‌تواند جزء خطی سری زمانی را پیش‌بینی کند و خطای مدل ARMA از جزء غیرخطی تشکیل شده است. در بخش دوم، جزء غیرخطی به عنوان ورودی یکی از مدل‌های شبکه‌های عصبی RNN، LSTM یا GRU برای پیش‌بینی استفاده می‌شود. در نهایت، جمع پیش‌بینی حاصل از مدل ARMA و مدل یادگیری عمیق به عنوان پیش‌بینی سری زمانی مورد نظر در نظر گرفته می‌شود. نمودار ۴ ساختار مدل ARMA-GRU که بر اساس مرحله سوم طراحی شده است را نشان می‌دهد.

ساختار مرحله چهارم

در مرحله چهارم مدل CEEMD و مدل AEMA با یکی از مدل‌های RNN، LSTM یا GRU ترکیب می‌شوند. بنابراین مرحله چهارم شامل سه مدل CEEMD-ARMA، CEEMD-ARMA-RNN و LSTM- و CEEMD-GRU می‌باشد. مدل CEEMD طبق رابطه ۲ سری زمانی را به مجموعه‌ای از IMF ها و باقیمانده با مقیاس‌های مشخصه و متفاوت تجزیه می‌کند.

$$s(t) = \sum_{i=1}^n imf_i(t) + res(t) \quad (2)$$

هر IMF و باقی مانده مقیاس زمانی مشخصه محلی خود را دارند. تست دیکي فولر (ADF) که می‌تواند در مورد ثابت بودن داده‌ها قضاوت کند. تست ADF از هر یک از IMF تست ریشه واحد می‌گیرد و وجود ریشه واحد در یک IMF نشان می‌دهد که IMF مورد نظر یک سری زمانی غیر خطی می‌باشد (بویوکشاهین و ارتکین ۲۰۱۹). برای پیش‌بینی IMF که ریشه واحد ندارند از مدل ARMA و برای IMF های که ریشه واحد دارند از یکی از مدل‌های یادگیری عمیق استفاده می‌شود و پیش‌بینی نهایی از مجموعه پیش‌بینی IMF تشکیل می‌شود. نمودار ۴ ساختار مدل CEEMD-ARMA-RNN بر اساس مرحله چهارم نمایش می‌دهد.

ساختار داده‌ها

در پژوهش حاضر برای بررسی کارایی مدل پیشنهادی از داده‌های شاخص کل بورس تهران برای پیش‌بینی روز آیند استفاده شده است. شاخص کل بیانگر سطح عمومی قیمت و سود سهام شرکت‌های پذیرفته شده در بورس است به عبارت دیگر، تغییرات شاخص کل بیانگر میانگین بازدهی سرمایه‌گذاران در

بورس است بنابراین ارزش تحقیقاتی زیادی دارد. شاخص کل تنها می‌تواند تغییرات کلی بازار را از دیدگاه کلان منعکس کند. همچنین باید سهام را که نماینده بازار هستند بررسی شود برای انتخاب سهام با کیفیت بالا، که از سوی مدیریت آمار و اطلاعات بورس تهران بر پایه ترکیبی از قدرت نقدشوندگی سهام و میزان داد و ستد سهام در تالار معاملات، تناوب داد و ستد سهام و معیار تاثیرگذاری شرکت بر بازار (میانگین تعداد سهام منتشر شده و میانگین ارزش جاری سهام در دوره بررسی) معرفی شده‌اند، استفاده شده است. داده‌های جمع آوری شده مربوط به بازه زمانی فروردین ۱۳۹۶ تا فروردین ۱۴۰۱ است. از ۸۰٪ ابتدایی داده‌ها برای آموزش، ۲۰٪ بعدی برای آزمون مدل‌ها استفاده شده است.

جدول ۱. توصیف آماری داده‌های شاخص کل و سهام

ردیف	نماد	تعداد داده‌ها	بیشترین مقدار	کم‌ترین مقدار	میانگین	انحراف استاندارد
۱	شاخص کل	۱،۲۰۰	۲،۰۷۸،۵۱۲	۷۷،۴۸۶	۶۳۹،۳۴۳	۵۹۴،۲۶۲
۲	فولاد	۱۵۸،۱	۳،۱۰۲	۵۱	۸۹۱	۸۷۲
۳	وغدیر	۱،۱۸۲	۵،۴۷۲	۱۵۸	۱،۳۹۴	۱،۳۷۱
۴	شاراک	۱،۱۷۸	۳۹،۸۰۶	۸۵۹	۱۰،۰۹۹	۱۰،۳۹۱
۵	کرماشا	۱،۱۷۷	۱۳،۵۷۰	۴۳۵	۴،۵۷۸	۴،۳۸۱
۶	وبانک	۱،۱۷۲	۳،۵۸۴	۱۱۰	۸۷۲	۷۹۷
۷	وصندوق	۱،۱۷۲	۹،۷۳۲	۳۲۲	۲،۹۱۷	۲،۸۲۲
۸	شپدیس	۱،۱۷۰	۱۳۸،۶۳۱	۲،۶۲۱	۳۶،۶۷۸	۳۹،۶۹۶
۹	پارسان	۱،۱۶۸	۲۴،۷۱۱	۷۳۹	۷،۵۲۷	۷،۴۱۴
۱۰	همراه	۱،۱۵۸	۱۰،۷۵۶	۶۲۲	۲،۴۸۸	۱،۸۷۵
۱۱	فخوز	۱،۱۵۶	۴،۰۶۷	۱۲۶	۱،۴۱۸	۱،۲۷۸
۱۲	کنور	۱،۱۵۲	۵،۴۹۵	۱۱۲	۱،۴۵۱	۱،۶۸۳
۱۳	کچاد	۱،۱۵۱	۴،۰۵۶	۷۱	۱،۱۳۹	۱،۱۸۳
۱۴	کاما	۱،۱۴۸	۱۰،۵۵۸	۸۶	۱،۷۹۶	۲،۲۶۴
۱۵	شیراز	۱،۱۴۷	۲۱،۵۸۶	۴۲۲	۶،۱۷۳	۶،۲۸۰
۱۶	ونفت	۱،۱۴۳	۶،۹۵۱	۲۹۷	۲،۰۹۳	۱،۶۸۲
۱۷	شبریز	۱،۱۴۲	۱۳،۲۵۳	۲۸۱	۳،۵۵۴	۳،۱۵۷
۱۸	فخاس	۱،۱۴۱	۱۴،۷۴۷	۶۴۸	۴،۲۷۴	۳،۳۲۶
۱۹	تاپیکو	۱،۱۴۰	۱۲،۷۷۷	۴۹۵	۳،۵۴۲	۳،۴۴۸
۲۰	خگستر	۱،۱۳۹	۱۲،۴۳۲	۸۵	۱،۵۹۵	۲،۱۰۷
۲۱	شغن	۱،۱۳۹	۱۴،۳۱۵	۳۲۲	۳،۶۰۲	۳،۷۸۰
۲۲	فملی	۱،۱۳۹	۳،۷۳۶	۷۰	۱،۱۳۷	۱،۱۷۸
۲۳	حکشتی	۱،۱۳۸	۱۶،۳۲۱	۴۴۷	۲،۱۶۶	۲،۵۸۵
۲۴	کگل	۱،۱۳۷	۵،۳۰۸	۹۸	۱،۵۷۶	۱،۶۱۶
۲۵	فارس	۱،۱۳۳	۵،۳۸۳	۱۸۱	۱،۶۰۶	۱،۶۰۶
۲۶	پاکشو	۱،۱۳۲	۷،۳۳۵	۱۶۱	۲،۳۶۴	۲،۳۸۱
۲۷	شینا	۱،۱۲۹	۴،۵۲۹	۷۴	۸۶۸	۸۹۸
۲۸	جم	۱،۱۲۰	۳۵،۹۳۸	۱،۸۸۸	۱۱،۸۵۳	۱۰،۸۹۸
۲۹	شخارک	۱،۱۱۴	۴۶،۵۴۳	۱،۹۲۰	۱۶،۶۶۸	۱۲،۶۶۴
۳۰	خپهن	۱،۱۰۹	۲،۸۴۷	۴۰	۶۴۲	۷۶۵

ردیف	نماد	تعداد داده‌ها	بیشترین مقدار	کم‌ترین مقدار	میانگین	انحراف استاندارد
۳۱	اخابر	۱،۱۰۲	۲۹،۱۳۰	۱،۱۵۰	۵،۲۷۲	۴،۸۲۶
۳۲	خودرو	۱،۱۰۰	۷،۶۶۰	۱۰۲	۱،۱۳۷	۱،۳۸۹
۳۳	شبندر	۱،۰۹۷	۶،۳۹۵	۱۸۱	۱،۵۷۲	۱،۵۲۸
۳۴	خسایا	۱،۰۴۴	۵،۷۴۰	۱۳۷	۱،۰۴۸	۱،۰۷۱
۳۵	وبملت	۱،۰۱۴	۱،۷۲۱	۵۹	۵۳۶	۴۹۲

منبع: یافته‌های پژوهش

معیارهای ارزیابی

در مدل‌های یادگیری عمیق معمولاً از خطای ضرر^۱ برای ارزیابی پیش‌بینی استفاده می‌شود که به تفاوت بین مقدار واقعی مشاهده شده و مقدار پیش‌بینی شده اشاره دارد. برای ارزیابی خطای ضرر می‌توان از ابزارهای مختلفی استفاده کرد. معیارهای استاندارد در این نوع مدل‌ها عبارتند از: ریشه-میانگین مربعات خطا^۲ (RMSE)، میانگین خطای مطلق^۳ (MAE) و میانگین درصد خطای مطلق^۴ (MAPE). فرمول محاسبه آنها به شرح زیر است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (۳)$$

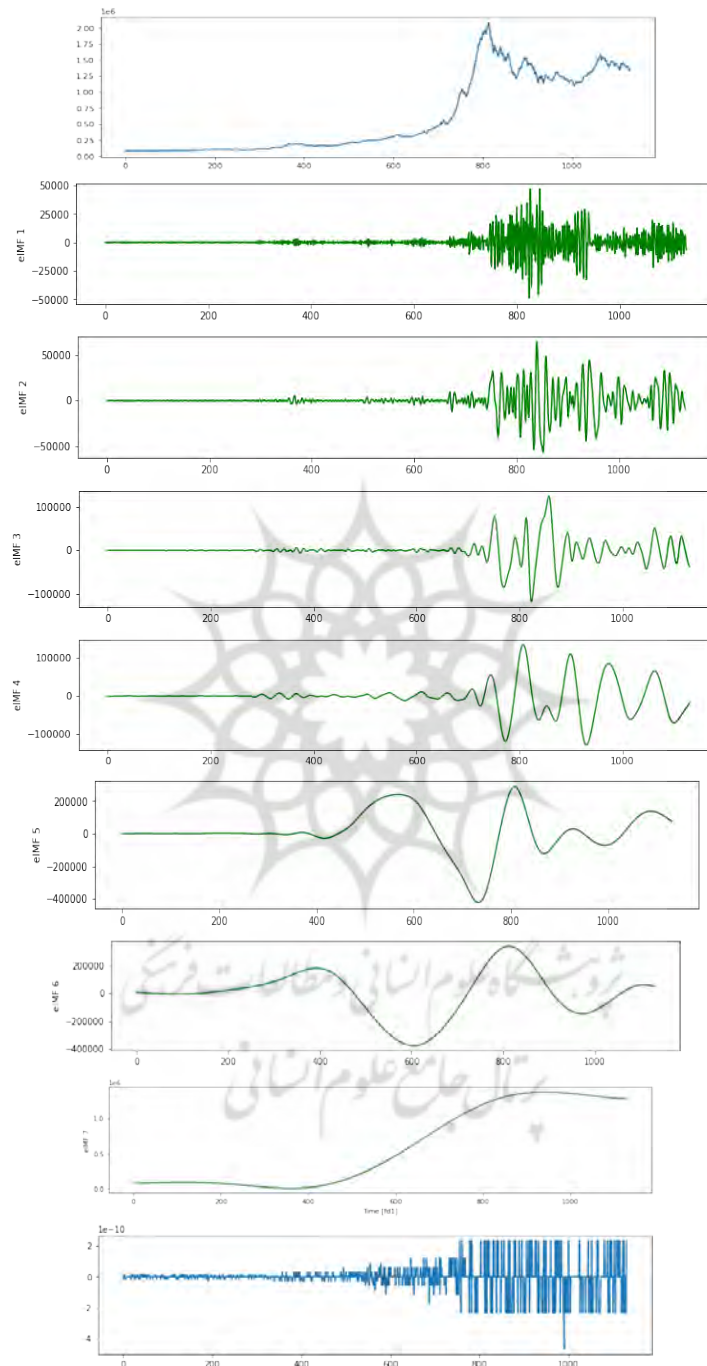
$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (۴)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (۵)$$

یافته‌های پژوهش

همانطور که قبلاً ذکر شده روش‌های تجزیه فرکنس داده‌ها را به طیف‌های فرکنسی مختلف تجزیه می‌کنند نمودار ۵ خروجی مدل CEEMD برای شاخص کل بورس تهران را نشان می‌دهد به عبارت دیگر، سری زمانی شاخص کل بورس تهران به مجموعه‌ای از IMFها و یک باقیمانده تجزیه می‌شود ترتیب IMFها از فرکنس بالا به پایین است که جزء باقیمانده در انتها قرار می‌گیرد چند IMF اول، با نوبز بیشتر، مؤلفه‌های فرکنس بالا را در داده‌های اصلی نشان می‌دهند و بیابگر عدم تعادل کوتاه‌مدت در بازار هستند چند IMF میانی، مؤلفه‌های فرکنس متوسط را نشان می‌دهند که ویژگی‌های نوسان بازار میان‌مدت که عمدتاً تحت تأثیر سیاست‌ها و مقررات است را بیان می‌کنند چند IMF آخر، با نوسانات کمتر، که مشبه روند حرکت بلندمدت سهام است، مؤلفه‌های فرکنس پایین را نشان می‌دهند

1. loss error
2. root-mean square error
3. mean absolute error
4. mean absolute percentage error



نمودار ۵. مولفه‌های IMF برای شاخص کل (منبع: یافته‌های پژوهش)

یافته‌های پیش‌بینی بر اساس ساختار مرحله اول

نتایج پیش‌بینی داده‌ها با استفاده از مدل‌های LSTM, RNN, GRU و ARMA که بر اساس ساختار مرحله اول طراحی شده‌اند، در جدول ۲ ارائه شده است. در بخش‌های بعدی، یافته‌های این قسمت با سه ساختار دیگر مقایسه می‌شود و تأثیر تجزیه داده‌ها بر عملکرد پیش‌بینی مدل‌های یادگیری ارزیابی می‌گردد. دقت پیش‌بینی نیز بر اساس سه معیار RMSE, MAE و MAPE سنجیده می‌شود.


جدول ۲. یافته‌های مدل‌های ساختار مرحله اول برای شاخص کل

مدل	تعداد لایه های مخفی	RMSE	MAE	MAPE (%)
ARMA	-	۱۳۰،۵۸۰	۱۱۴،۶۹۱	۸،۵۵٪
RNN	۱	۱۳۵،۶۱۳	۱۲۰،۱۹۸	۹،۰۱٪
	۲	۱۳۶،۸۶۲	۱۲۱،۳۰۵	۹،۰۹٪
	۳	۱۲۸،۸۰۰	۱۱۴،۵۷۲	۸،۵۶٪
LSTM	۴	۱۳۶،۶۹۷	۱۲۱،۱۵۹	۹،۰۸٪
	۱	۱۲۰،۱۶۱	۶۵،۸۶۲	۴،۹۴٪
	۲	۹۶،۷۲۳	۵۳،۰۱۵	۳،۹۷٪
GRU	۳	۹۴،۸۱۶	۵۲،۲۸۸	۳،۹۰٪
	۴	۱۲۶،۳۹۲	۶۹،۴۷۷	۵،۱۹٪
	۱	۹۸،۹۰۸	۶۲،۶۹۳	۴،۷۴٪
GRU	۲	۹۸،۲۸۵	۶۲،۸۷۴	۴،۷۱٪
	۳	۱۰۶،۶۶۹	۶۸،۲۳۷	۵،۱۲٪
	۴	۱۱۰،۵۴۸	۷۰،۷۱۸	۵،۳۰٪


منبع: یافته‌های پژوهش

طبق معیار *MAPE*، مدل LSTM با سه لایه مخفی با خطای ۳،۹ درصدی، بهترین عملکرد را نسبت به سایر مدل‌های ساختار اول داشته است و مدل RNN-2-LAYER با *MAPE* برابر ۹،۰۹ درصد، بدترین عملکرد را در بین این مدل‌ها کسب کرده است. نمودار ۶ مقادیر واقعی و پیش‌بینی شده برای مدل‌های ARMA, LSTM, RNN, GRU با کمترین مقدار خطا نمایش می‌دهد و نمودار ۷ روند درصد خطای *MAPE* مدل LSTM-3-LAYER را نشان می‌دهد همانطور که مشخص است مدل LSTM-3-LAYER در اکثر مواقع بیش‌بینی، مقدار پیش‌بینی شده بیشتر از مقدار واقعی بوده است مدل LSTM-3-LAYER انتظار عدد بالاتری نسبت به مقدار واقعی داشته است. هر چند این مدل بهترین نتایج پیش‌بینی بر اساس مرحله اول برای شاخص کل ارائه کرده است ولی درصد خطای مدل در طول فرآیند پیش‌بینی یکسان نیست به عبارت دیگر واریانس خطا زیاد می‌باشد بعضی وقت‌ها درصد خطای مدل بیش‌تر از مقدار میانگین خطای مدل است. به همین دلیل استفاده از این مدل‌های می‌تواند با ریسک زیادی همراه باشند چرا که مهم است در طول فرآیند پیش‌بینی درصد خطا به صورت موضعی باید یکسان باشند.

طبق معیار MAPE، مدل LSTM با سه لایه مخفی و خطای ۳٫۹ درصدی، بهترین عملکرد را نسبت به سایر مدل‌های ساختار اول داشته است. در مقابل، مدل -LAYER۲RNN- با MAPE برابر ۹٫۰۹ درصد، بدترین عملکرد را در بین این مدل‌ها کسب کرده است. نمودار ۶ مقادیر واقعی و پیش‌بینی شده برای مدل‌های LSTM، GRU، RNN و ARMA با کمترین مقدار خطا را نمایش می‌دهد و نمودار ۷ روند درصد خطای MAPE مدل -LAYER۳LSTM- را نشان می‌دهد. همانطور که مشخص است، مدل -LAYER۳LSTM- در اکثر مواقع پیش‌بینی، مقدار پیش‌بینی شده بیشتری نسبت به مقدار واقعی داشته است. به عبارت دیگر، مدل -LAYER۳LSTM- انتظار عدد بالاتری نسبت به مقدار واقعی داشته است. هر چند این مدل بهترین نتایج پیش‌بینی بر اساس مرحله اول برای شاخص کل ارائه کرده است، ولی درصد خطای مدل در طول فرآیند پیش‌بینی یکسان نیست. به عبارت دیگر، واریانس خطا زیاد است و بعضی مواقع درصد خطای مدل بیشتر از مقدار میانگین خطای مدل است. به همین دلیل، استفاده از این مدل‌ها می‌تواند با ریسک زیادی همراه باشد، چرا که مهم است در طول فرآیند پیش‌بینی، درصد خطا به صورت موضعی یکسان باشد.



نمودار ۶. پیش‌بینی شاخص کل بر اساس مدل‌های ساختار مرحله اول (منبع: یافته‌های پژوهش)



نمودار ۷. روند مقدار خطای LSTM-3-LAYER برای شاخص کل (منبع: یافته‌های پژوهش)


پیش‌بینی بر اساس ساختار مرحله دوم یا CD
جدول ۳ میزان خطای مدل‌های مرحله دوم یا CD را که توسط سه معیار RMSE ، MAE و MAPE ارزیابی شده‌اند، نمایش می‌دهد.

جدول ۳. یافته‌های مدل‌های ساختار مرحله دوم برای شاخص کل


مدل	تعداد لایه‌های مخفی	RMSE	MAE	MAPE
CEEMD-RNN	۱	۷۲،۰۹۵	۵۵،۸۳۶	۴،۲۲٪
	۲	۸۱،۳۶۸	۶۳،۵۹۴	۴،۷۷٪
	۳	۸۴،۵۰۸	۶۶،۰۴۹	۴،۹۵٪
	۴	۸۶،۰۶۱	۶۷،۲۶۳	۵،۰۴٪
CEEMD-LSTM	۱	۵۴،۲۵۸	۴۴،۲۹۴	۳،۳۳٪
	۲	۶۰،۵۴۱	۴۹،۶۴۰	۳،۷۲٪
	۳	۶۳،۳۳۹	۵۱،۹۳۵	۳،۸۹٪
	۴	۵۶،۷۹۹	۴۶،۵۷۲	۳،۴۹٪
CEEMD-GRU	۱	۱۸،۷۶۸	۱۴،۸۲۰	۱،۱۰٪
	۲	۳۴،۸۸۶	۲۷،۳۶۱	۲،۰۵٪
	۳	۳۶،۲۹۸	۲۸،۴۶۹	۲،۱۳٪
	۴	۳۰،۰۵۶	۲۳،۵۷۳	۱،۷۷٪

منبع: یافته‌های پژوهش

طبق سه معیار RMSE، MAE و MAPE، مدل CEEMD-GRU-1-LAYER با ۱،۱۰٪ درصد خطای MAPE، بهترین عملکرد را نسبت به سایر مدل‌های مرحله دوم دارد، در حالی که مدل CEEMD-LAYER\GRU بدترین عملکرد را کسب کرده است. نمودار ۸ مقادیر واقعی و پیش‌بینی شده با کمترین مقادیر برای مدل‌های مرحله دوم را نمایش می‌دهد. نمودار ۹ روند مقدار خطای MAPE برای مدل CEEMD-GRU-LAYER را نشان می‌دهد که حول محور صفر به بالا و پایین نوسان می‌کند و به صورت موضعی نسبت به صفر متقارن است. در مدل CEEMD-GRU-1-LAYER نسبت به مدل LSTM-3-LAYER، نوسانات خطای MAPE در طول فرآیند پیش‌بینی کاهش پیدا کرده است، ولی همچنان بالاست.



نمودار ۸. پیش‌بینی شاخص کل بر اساس چهار مدل ساختار CD (منبع: یافته‌های پژوهش)



نمودار ۹. روند مقدار خطای MAPE مدل CEEMD-GRU-1-LAYER برای شاخص کل (منبع: یافته‌های پژوهش)

پیش‌بینی بر اساس مرحله سوم

جدول ۴ میزان خطای مدل‌های گروه مرحله سوم را که توسط سه معیار MAPE و MAE، RMSE ارزیابی شده‌اند، برای شاخص کل نمایش می‌دهد.

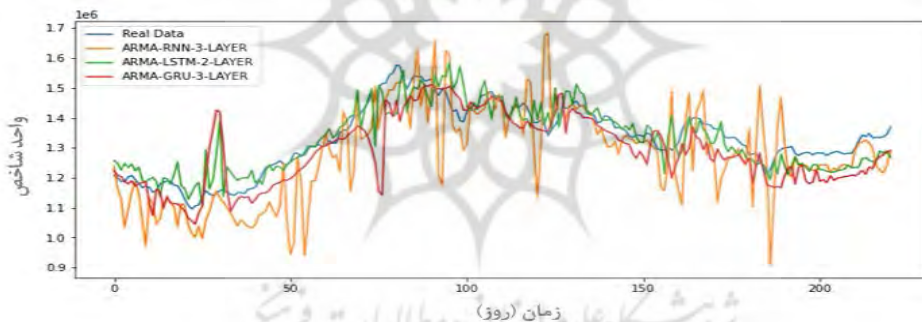
جدول ۴. یافته‌های مدل‌های ساختار AD برای شاخص کل

MAPE	MAE	RMSE	تعداد لایه‌ها مخفی	مدل
۶.۱۹٪	۸۱.۲۳۸	۱۰۸.۴۰۵	۱	ARMA-RNN
۷.۹۱٪	۱۰۳.۷۴۵	۱۳۸.۱۸۳	۲	
۷.۰۸٪	۹۲.۹۴۵	۱۲۳.۷۹۹	۳	
۸.۰۹٪	۱۰۶.۰۹۴	۱۴۱.۳۱۲	۴	
۴.۰۰٪	۵۳.۵۶۲	۶۹.۹۲۶	۱	ARMA-LSTM
۳.۱۷٪	۴۱.۹۷۴	۵۵.۲۶۲	۲	
۴.۳۱٪	۵۷.۴۷۱	۷۵.۰۲۹	۳	
۴.۱۶٪	۵۵.۵۲۳	۷۲.۴۸۶	۴	
۴.۴۶٪	۵۹.۰۰۷	۷۸.۷۴۰	۱	ARMA-GRU
۴.۹۵٪	۶۵.۴۷۶	۸۷.۳۷۲	۲	
۴.۹۹٪	۶۶.۱۱۱	۸۸.۲۲۰	۳	
۴.۵۰٪	۵۹.۵۸۴	۷۹.۵۱۰	۴	


(منبع: یافته‌های پژوهش)

طبق سه معیار $RMSE$ ، MAE و $MAPE$ مدل $ARMA-LSTM2LAYER$ با $3,17\%$ درصد خطای $MAPE$ بهترین عملکرد را دارد دقت مدل $ARMA-LSTM2LAYER$ در مقایسه با مدل $LAYER2LSTM$ تقریباً 1% درصد افزایش یافته است ولی نسبت به مدل $LAYER1CEEMD-GRU$ دقت پیش‌بینی 2% درصد کمتر است.

نمودار 10 مقادیر واقعی و پیش‌بینی شده برای بهترین مدل‌های GRU ، $LSTM$ ، RNN و $ARMA$ بر اساس مرحله سوم را نمایش می‌دهد. طبق نمودار 10 ، نتایج پیش‌بینی مدل $ARMA-2LAYER$ ، $LSTM$ تقریباً نزدیک به مقدار واقعی است، در حالی که نتایج مدل‌های $ARMA-GRU-LAYER-3$ و $ARMA-RNN-LAYER-3$ بدترین نتایج را ارائه کرده‌اند. نمودار 11 روند مقدار خطای $MAPE$ برای مدل $ARMA-LSTM-2-LAYER$ را نشان می‌دهد که حول محور صفر به بالا و پایین نوسان می‌کند و به صورت موضعی نسبت به صفر متقارن است. با این حال، درصد خطای مدل در طول فرآیند پیش‌بینی یکسان نیست؛ به عبارت دیگر، واریانس خطا زیاد است. مدل $ARMA-LSTM2LAYER$ در اکثر مواقع مقدار کمتری نسبت به مقدار واقعی پیش‌بینی کرده است. به عبارت دیگر، مدل $ARMA-2LAYER$ $LSTM$ انتظار عدد پایین‌تری داشته است، ولی شاخص کل برخلاف آن پیش رفته و عدد بالاتری از مقدار پیش‌بینی ثبت کرده است.



نمودار 10 . پیش‌بینی شاخص کل بر اساس مرحله سوم یا AD (منبع: یافته‌های پژوهش)



نمودار 11 . خطای مدل $ARMA-LSTM-2-LAYER$ برای شاخص کل (منبع: یافته‌های پژوهش)

پیش‌بینی بر اساس مرحله چهارم

جدول ۵ عملکرد مدل‌های گروه مرحله چهارم را که توسط سه معیار RMSE، MAE و MAPE ارزیابی شده‌اند، برای شاخص کل نمایش می‌دهد.

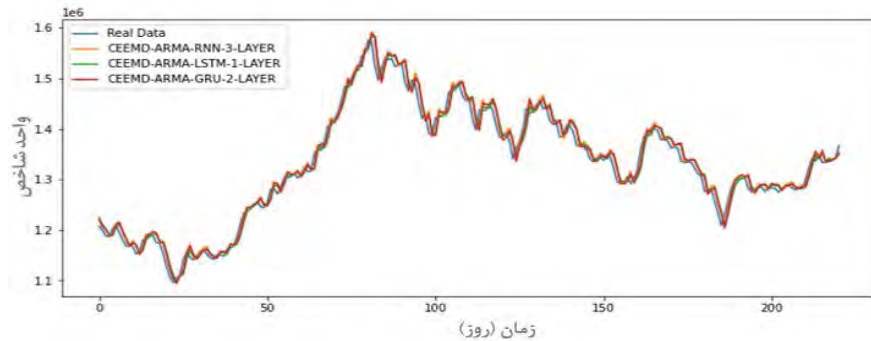
جدول ۵. یافته‌های مرحله چهارم برای شاخص کل

مدل	تعداد لایه‌ها مخفی	RMSE	MAE	MAPE
CEEMD-ARMA-RNN	۱	۱۶.۲۸۸	۱۲.۶۳۶	۰.۹۴٪
	۲	۲۲.۲۸۷	۱۷.۲۹۰	۱.۲۹٪
	۳	۲۴.۳۳۹	۱۸.۸۸۲	۱.۴۱٪
CEEMD-ARMA-LSTM	۴	۲۱.۴۲۴	۱۶.۶۲۱	۱.۲۴٪
	۱	۱۶.۴۵۸	۱۲.۵۱۷	۰.۹۴٪
	۲	۱۷.۵۶۲	۱۳.۳۴۱	۱.۰۰٪
	۳	۱۷.۹۳۱	۱۳.۶۲۱	۱.۰۲٪
CEEMD-ARMA-GRU	۴	۱۷.۶۳۲	۱۳.۳۹۴	۱.۰۰٪
	۱	۱۶.۲۱۵	۱۲.۵۵۸	۰.۹۴٪
	۲	۱۶.۵۳۷	۱۳.۰۴۷	۰.۹۶٪
	۳	۱۶.۹۰۰	۱۳.۷۲۷	۰.۹۸٪
	۴	۱۷.۷۸۲	۱۰.۷۸۵۸	۱.۰۳٪


منبع: یافته‌های پژوهش

طبق سه معیار RMSE، MAE و MAPE، مدل ۱-LAYER-CEEMD-ARMA-LSTM با ۰.۹۴ درصد خطای MAPE، بهترین عملکرد را در مقایسه با سایر مدل‌های مرحله چهارم دارد. دقت مدل ۱-LAYER-CEEMD-ARMA-LSTM در مقایسه با مدل ۳-LAYER-LSTM تقریباً ۳ درصد افزایش یافته است و نسبت به مدل ۱-LAYER-CEEMD-GRU دقت پیش‌بینی ۲ درصد افزایش پیدا کرده است.

نمودار ۱۲ مقادیر واقعی و پیش‌بینی شده توسط بهترین مدل‌های ARMA، LSTM، GRU و RNN را در مرحله چهارم نشان می‌دهد. طبق این نمودار، نتایج پیش‌بینی مدل ۱-LAYER-CEEMD-ARMA-LSTM به مقادیر واقعی نزدیک است. نمودار ۱۳ روند مقدار خطای MAPE برای مدل ۱-LAYER-CEEMD-ARMA-LSTM را نشان می‌دهد که حول محور صفر نوسان می‌کند و به صورت موضعی نسبت به صفر متقارن است. واریانس خطای مدل ۱-LAYER-CEEMD-ARMA-LSTM در مقایسه با سایر مدل‌ها کمترین مقدار را دارد. در اکثر مواقع، پیش‌بینی مدل ۱-LAYER-CEEMD-ARMA-LSTM بیشتر از مقدار واقعی بوده است.



نمودار ۱۲. پیش‌بینی شاخص کل توسط CAD (منبع: یافته‌های پژوهش)



نمودار ۱۳. روند مقدار خطای MAPE مدل ۱-LAYER-CEEMD-LSTM برای شاخص کل (منبع: یافته‌های پژوهش)

آنالیز رگرسیون

برای ارزیابی همبستگی بین داده‌های واقعی و مقادیر پیش‌بینی شده، یک رگرسیون خطی انجام می‌شود. مقدار پیش‌بینی شده به ترتیب x و مقدار واقعی y است. معادله رگرسیون $y = ax + b$ است. معیارها شامل خطای استاندارد^۱ (SE)، p -value (p) و t -value (t)، برای آزمایش نتایج تحلیل رگرسیون استفاده می‌شود. تعاریف SE و t به شرح زیر است و p از توزیع t مشتق شده است.

$$SE = \frac{\sigma}{\sqrt{n}} \quad (۶)$$

$$t = \frac{x - \mu}{\frac{\sigma}{\sqrt{n}}} \quad (۷)$$

1 . standard error



در اینجا σ انحراف معیار مقادیر پیش‌بینی‌شده، n تعداد مقادیر پیش‌بینی‌شده (یا واقعی)، X میانگین مقادیر پیش‌بینی‌شده و μ میانگین مقادیر واقعی است. جدول ۵ پارامترهای رگرسیون و نتایج پیش‌بینی را نشان می‌دهد. مشاهده می‌شود که شیب a هر مدل برای شاخص کل نزدیک به ۱ است، SE برای a نسبتاً کوچک به این معنی که مقادیر پیش‌بینی شده بسیار نزدیک به مقادیر واقعی هستند.

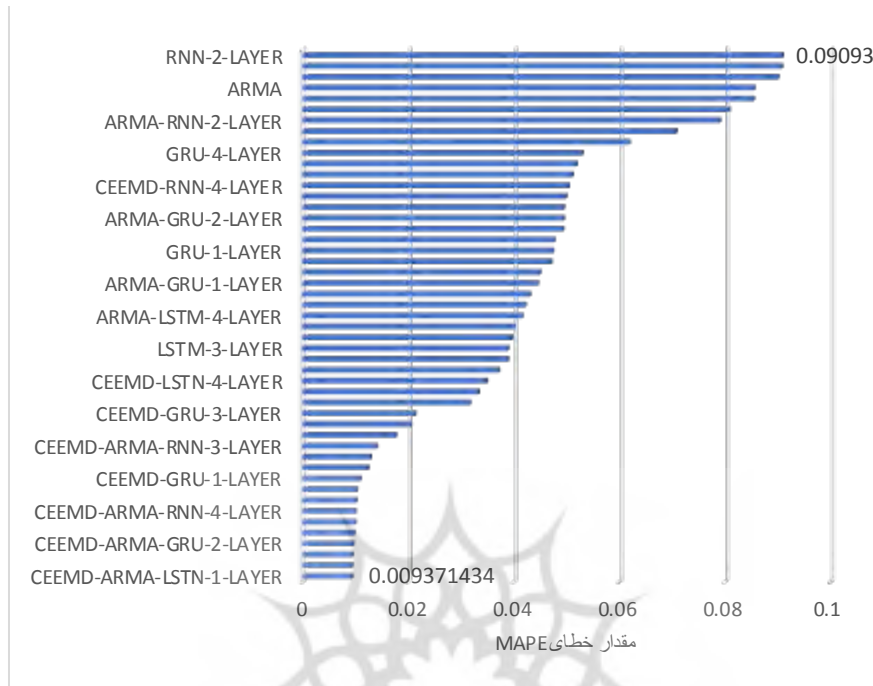
جدول ۶. پارامترهای رگرسیون و نتایج پیش‌بینی

مدل	پارامتر	برآورد شده	SE	t	p
LSTM-3-LAYER	a	۰.۹۹۶	۰.۰۰۵	۱۹۴.۲۹۱	۰
	b	۴۷۶.۰۴۴	۶۸۳.۴۶۲	۰.۰۷	۰.۹۴۵
CEEMD-GRU-1-LAYER	a	۰.۹۹۴	۰.۰۰۳	۲۸۸.۶۳	۰
	b	۷.۷۹۷.۱۱	۴.۵۷۵۵۰	۱.۷۰۴	۰.۰۹
LAYER-2-ARMA-LSTM	a	۱.۰۰۲	۰.۰۰۲	۴۸۴.۶۲۲	۰
	b	-۳۰.۸۳.۳۰	۲.۷۴۷.۴۶	-۱.۱۲۲	۰.۲۶۳
1-LAYER-CEEMD-ARMA-LSTM	a	۱	۰	۵.۹۷۲.۲۳	۰
	b	-۱۳.۹۲۷	۲۲۲.۴۳۳	-۰.۰۶۳	۰.۹۵

منبع: یافته‌های پژوهش

مقایسه مدل‌ها بر حسب داده‌های شاخص کل

بر اساس چهار جدول بالا، تجزیه داده‌های سری زمانی تأثیر بسزایی در عملکرد مدل‌های یادگیری دارد. نمودار ۱۴ به وضوح کارایی ترکیب روش‌های تجزیه سری زمانی با مدل‌های یادگیری عمیق را نشان می‌دهد. تجزیه داده‌ها پیچیدگی آن‌ها را کاهش داده و فرآیند استخراج ویژگی را برای مدل‌های یادگیری تسهیل می‌کند. بدیهی است که تحلیل IMF‌های پایدار و کم‌نوسان بسیار آسان‌تر از سری‌های زمانی ناپایدار و با نوسان زیاد است. همچنین، ترکیب مدل ARMA با مدل‌های یادگیری عمیق، دقت پیش‌بینی مدل‌ها را افزایش می‌دهد. نمودار ۱۴ خطای تمام مدل‌ها را بر اساس معیار MAPE نمایش می‌دهد که بهترین مدل برای پیش‌بینی شاخص کل، مدل ۱-LAYER-CEEMD-ARMA-LSTM با خطای ۰.۹۴ درصد و بدترین مدل، مدل LAYER-RNN- با خطای ۹.۰۹ درصد است.




نمودار ۱۴. مقایسه مدل‌ها در چهار مرحله برای شاخص کل بر اساس خطای MAPE (منبع: یافته‌های پژوهش حاضر)

یافته‌های پژوهش برای سهام

برای ارزیابی دقت پیش‌بینی مدل‌های این پژوهش از داده‌های سهام ۳۴ شرکت استفاده شده است و برای داده‌های هر سهم، تمام مدل‌های چهار مرحله اجرا شده و بهترین مدل برای آن سهم بر اساس کمترین میانگین درصد خطای مطلق در نظر گرفته شده است. نمودار ۱۵ بیان می‌کند مدل CEEMD-ARMA-LSTM-4-LAYER برای ۱۰ سهم، مدل‌های CEEMD-LSTM-1-LAYER و مدل CEEMD-ARMA-GRU-1-LAYER هر کدام برای ۵ سهم، مدل‌های CEEMD-ARMA-LSTM-1-LAYER و مدل CEEMD-ARMA-GRU-2-LAYER هر کدام برای ۴ سهم، مدل‌های CEEMD-ARMA-GRU-3-LAYER هر کدام برای ۳ سهم، بهترین عملکرد طبق معیار کمترین میانگین درصد خطای مطلق را کسب کردند.

برای ارزیابی دقت پیش‌بینی مدل‌های این پژوهش، از داده‌های سهام ۳۴ شرکت استفاده شده است. برای داده‌های هر سهم، تمام مدل‌ها در چهار مرحله اجرا شدند و بهترین مدل برای آن سهم بر اساس کمترین میانگین درصد خطای مطلق انتخاب شده است. نمودار ۱۵ نشان می‌دهد که مدل CEEMD-ARMA-LSTM-4-LAYER برای ۱۰ سهم، مدل‌های CEEMD-LSTM-1-LAYER و CEEMD-ARMA-GRU-4-LAYER هر کدام برای ۵

سهیم، مدل‌های CEEMD-ARMA-GRU-1-LAYER و CEEMD-ARMA-LSTM-1-LAYER هر کدام برای ۴ سهیم و مدل‌های CEEMD-GRU-2-LAYER و CEEMD-ARMA-GRU-3-LAYER هر کدام برای ۳ سهیم، بهترین عملکرد را طبق معیار کمترین میانگین درصد خطای مطلق کسب کرده‌اند.



نمودار ۱۵. بهترین مدل‌ها بر اساس MAPE برای سهام شرکت‌ها (منبع: یافته‌های پژوهش)

نتیجه‌گیری

در این پژوهش، تلاش شد تا ترکیبی از مدل‌های یادگیری عمیق و تجزیه فرکانسی به منظور پیش‌بینی قیمت روزانه سهام برای روز آینده طراحی شود. در این راستا، چهار ساختار متفاوت مبتنی بر مدل‌های یادگیری عمیق و تجزیه داده‌ها طراحی شدند. در ساختار اول، مدل‌های یادگیری عمیق بر اساس تعداد لایه‌های مخفی از یک لایه تا چهار لایه طراحی شدند. یافته‌های ساختار اول نشان می‌دهد که تعداد لایه‌های مخفی تأثیر بسزایی در عملکرد مدل‌های یادگیری عمیق دارد. با توجه به پژوهش متوسلی و کاشفی (۲۰۰۶) که سهام ۴۰ شرکت فعال‌تر پذیرفته شده در بورس تهران برای دوره‌های زمانی ۱۳۸۱ تا ۱۳۸۴ پیش‌بینی کردند، دریافتند در ۳۰ مورد از شرکت‌ها، مدل ARIMA به‌طور معنی‌داری نسبت به مدل‌های شبکه عصبی عملکرد بهتری دارد. ولی یافته‌های ساختار اول نشان می‌دهد که اگر پارامترهای مدل‌های شبکه‌های عصبی به‌طور بهینه انتخاب شوند، می‌توانند بهتر از مدل‌های خطی پیچیدگی‌های سری زمانی قیمت سهام را تجزیه و تحلیل کنند. طبق ساختار مرحله اول، مدل LSTM با سه لایه مخفی و ۳٫۹ درصد خطای MAPE، در مقایسه با سایر مدل‌های این ساختار بهترین عملکرد را کسب کرد.

در ساختار مرحله دوم که به دنبال تأثیر تجزیه داده‌ها به روش CEEMD بر عملکرد مدل‌های یادگیری عمیق بود، یافته‌ها نشان می‌دهد که تجزیه داده‌ها به روش CEEMD می‌تواند پیچیدگی سری‌های زمانی را کاهش دهد و استخراج الگوها را برای مدل‌های یادگیری عمیق تسهیل کند. در نتیجه، این روش

تأثیر بسزایی بر دقت مدل‌های یادگیری عمیق دارد. یافته‌های این مرحله با پژوهش‌های فلاح‌پور و علی‌پور (۲۰۱۴) در خصوص نوپزدایی داده‌ها جهت افزایش دقت شبکه عصبی در پیش‌بینی متغیرهای مالی هم‌راستا است. به عبارت دیگر، نوپزدایی داده‌ها سبب افزایش دقت شبکه عصبی پیش‌بینی می‌شود. طبق یافته‌های مرحله دوم، مدل CEEMD-GRU با یک لایه مخفی و ۱٫۱ درصد خطای MAPE در مقایسه با سایر مدل‌های این مرحله بهترین عملکرد را برای پیش‌بینی شاخص کل داشته است. همچنین، مدل CEEMD-GRU-2-LAYER برای ۳ سهم و مدل CEEMD-LSTM-1-LAYER برای ۵ سهم بهترین عملکرد را داشته‌اند.

در ساختار سوم، که به دنبال تأثیر مدل آماری ARMA در عملکرد پیش‌بینی مدل‌های یادگیری عمیق بود، یافته‌ها نشان می‌دهد ترکیب مدل ARMA با مدل‌های RNN، LSTM و GRU دقت این مدل‌ها را افزایش می‌دهد. این یافته‌ها، یافته‌های ژانگ (۲۰۰۳) مبنی بر اینکه ترکیب مدل ARMA با مدل شبکه عصبی مصنوعی (ANN) دقت پیش‌بینی را افزایش می‌دهد، تأیید می‌کند. مدل‌های ARMA-RNN، ARMA-LSTM و ARMA-GRU نسبت به مدل‌های RNN، LSTM و GRU عملکرد بهتری داشته‌اند. البته از مقایسه یافته‌های ساختارهای مرحله سوم و مرحله دوم می‌توان دریافت که مدل CEEMD تأثیر بیشتری نسبت به مدل ARMA بر دقت پیش‌بینی مدل‌های یادگیری عمیق دارد.

در ساختار چهارم، سعی بر این شده که مدلی برای پیش‌بینی قیمت سهام طراحی شود که ترکیبی از CEEMD، ARMA و مدل‌های یادگیری عمیق باشد. یافته‌های این قسمت نشان می‌دهد که ترکیب CEEMD و ARMA با مدل‌های یادگیری عمیق، دقت بیشتری نسبت به استفاده از هر یک به تنهایی دارد. طبق سه معیار RMSE، MAE و MAPE، مدل ۱-LAYER-CEEMD-ARMA-LSTM با ۰٫۹۴ درصد خطای MAPE، در مقایسه با سایر مدل‌های استفاده شده در این پژوهش، بهترین عملکرد را برای شاخص کل داشته است. نمودار ۱۵ نشان می‌دهد که مدل‌های ساختار چهارم برای ۲۶ مورد از سهام، نسبت به سه ساختار دیگر برای پیش‌بینی ۳۴ سهام، عملکرد بهتری کسب کرده‌اند.

در ساختار چهارم، سعی بر این شده که مدلی برای پیش‌بینی قیمت سهام طراحی شود که ترکیبی از CEEMD، ARMA و مدل‌های یادگیری عمیق باشد. یافته‌های این قسمت نشان می‌دهد که ترکیب CEEMD و ARMA با مدل‌های یادگیری عمیق، دقت بیشتری نسبت به استفاده از هر یک به تنهایی دارد. طبق سه معیار RMSE، MAE و MAPE، مدل ۱-LAYER-CEEMD-ARMA-LSTM با ۰٫۹۴ درصد خطای MAPE، در مقایسه با سایر مدل‌های استفاده شده در این پژوهش، بهترین عملکرد را برای شاخص کل داشته است. نمودار ۱۵ نشان می‌دهد که مدل‌های ساختار چهارم برای ۲۶ مورد از ۳۴ سهامی که در این پژوهش با استفاده از مدل‌های چهار ساختار طراحی شده پیش‌بینی شده‌اند، عملکرد بهتری کسب کرده‌اند.

به علت نوسانات درصد خطای پیش‌بینی در طول فرآیند پیش‌بینی، استفاده از این مدل‌ها به تنهایی پر ریسک می‌باشد. پیشنهاد می‌شود از چند مدل برای پیش‌بینی استفاده شود. همچنین، همان‌طور که

نمودار ۱۵ نشان می‌دهد، بهترین مدل این پژوهش لزوماً برای همه سهام بهترین عملکرد را ندارد و برای هر سهم باید پارامترهای مدل مورد نظر متناسب با نوع سهم به صورت بهینه انتخاب شوند. با توجه به یافته‌های پژوهش حاضر، پیشنهاد می‌شود برای افزایش دقت پیش‌بینی، تعداد لایه‌های مخفی مدل‌های یادگیری عمیق متناسب با نوع بازار، به صورت بهینه انتخاب شود. برای تسهیل استخراج الگوهای پنهان سری‌های زمانی توسط مدل‌های یادگیری عمیق، از داده‌های هفتگی یا ماهانه استفاده شود، چرا که استفاده از داده‌های هفتگی یا ماهانه در مقایسه با داده‌های روزانه سری هموارتری ارائه می‌دهند و سبب کاهش نویز در داده‌ها می‌شوند. منابع دیگری وجود دارند که می‌توان از آن‌ها برای بهبود پیش‌بینی بهره برد. استفاده از اخبار و همچنین، توپیت‌های شبکه اجتماعی ایکس و تحلیل اثر آن‌ها بر بازارهای مالی می‌تواند در پژوهش‌های آتی به ساختارهای پیشنهادی اضافه شود. برای این کار می‌توان شبکه عمیق دیگری را به صورت موازی با چارچوب‌های پیشنهادی طراحی کرد که در انتها اطلاعات داده‌های متنی را با چارچوب‌های فعلی ترکیب می‌کند و پس از آن پیش‌بینی صورت می‌پذیرد.

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.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

References

- Aggarwal, A.; Gupta, I.; Garg, N.; & Goel, A. (2019). Deep learning approach to determine the impact of socio-economic factors on bitcoin price prediction. In 2019 Twelfth International Conference on Contemporary Computing (IC3) (pp. 1-5). IEEE.
- Ali, M.; Prasad, R.; Xiang, Y.; & Yaseen, Z. M. (2020). Complete ensemble empirical mode decomposition hybridized with random forest and kernel ridge regression model for monthly rainfall forecasts. *Journal of Hydrology*, 584, 124647.
- Bao, W.; Yue, J.; & Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLOS ONE*, 12(7), e0180944.
- Büyüksahin, Ü. Ç.; & Ertekin, Ş. (2019). Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition. *Neurocomputing*, 361, 151-163.
- Chen, L.; Chi, Y.; Guan, Y.; & Fan, J. (2019). A hybrid attention-based EMD-LSTM model for financial time series prediction. In 2019 2nd International Conference on Artificial Intelligence and Big Data (ICAIBD) (pp. 113-118). IEEE.
- Chen, R.; & Pan, B. (2016). Chinese stock index futures price fluctuation analysis and prediction based on complementary ensemble empirical mode decomposition. *Mathematical Problems in Engineering*, 2016(1), 3791504.
- Choi, D. (2019). On empirical comparisons of optimizers for deep learning. arXiv preprint arXiv:1910.05446.
- Fallahpour, S.; & Alipour Reikandeh, J. (2014). Prediction of stock index using wavelet neural networks in Tehran Stock Exchange. *Financial management strategy*, 2(4), 15-31. (In Persian)
- 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.
- Gan, L.; Wang, H.; & Yang, Z. (2020). Machine learning solutions to challenges in finance: An application to the pricing of financial products. *Technological Forecasting and Social Change*, 153, 119928.
- Hochreiter, S.; & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Hsieh, T. J.; Hsiao, H. F.; & Yeh, W. C. (2011). Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm. *Applied Soft Computing*, 11(2), 2510-2525.
- Huang, N. E.; Shen, Z.; Long, S. R.; Wu, M. C.; Shih, H. H.; Zheng, Q.; & Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 454(1971), 903-995.
- Jin, Z.; Yang, Y.; & Liu, Y. (2020). Stock closing price prediction based on sentiment analysis and LSTM. *Neural Computing and Applications*, 32, 9713-9729.
- Jothimani, D.; & Yadav, S. S. (2019). Stock trading decisions using ensemble-based forecasting models: a study of the Indian stock market. *Journal of Banking and Financial Technology*, 3(2), 113-129.

- Khashei, M; & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664-2675.
- Liu, Y. (2019). Novel volatility forecasting using deep learning–long short-term memory recurrent neural networks. *Expert Systems with Applications*, 132(1), 99-109.
- Lv, P; Wu, Q; Xu, J; & Shu, Y. (2022). Stock index prediction based on time series decomposition and hybrid model. *Entropy*, 24(2), 146.
- Masters, D; & Luschi, C. (2018). Revisiting small batch training for deep neural networks. *arXiv preprint arXiv:1804.07612*.
- McNally, S. (2016). Predicting the price of Bitcoin using machine learning. Dissertation. National College of Ireland, Dublin, Ireland.
- Motevasseli, M; & Taleb Kashefi, B. (2006). A comparative study of neural networks' capabilities using indicators of technical analysis for forecasting of stock's price. *Journal of Economic Studies and Policies*, 9(1), 57-82. (In Persian)
- Nelson, D. M; Pereira, A. C; & De Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. In 2017 International Joint Conference on Neural Networks (IJCNN) (pp. 1419-1426). IEEE.
- Niu, H; Xu, K; & Wang, W. (2020). A hybrid stock price index forecasting model based on variational mode decomposition and LSTM network. *Applied Intelligence*, 50(3), 4296-4309
- Polanco-Martínez, J. M. (2019). Dynamic relationship analysis between NAFTA stock markets using nonlinear, nonparametric, non-stationary methods. *Nonlinear Dynamics*, 97(1), 369-389.
- Rezaei, H; Faaljou, H; & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169(1), 114332.
- Shafi, I; Ahmad, J; Shah, S. I; & Kashif, F. M. (2006). Impact of varying neurons and hidden layers in neural network architecture for a time frequency application. In 2006 IEEE International Multitopic Conference (pp. 188-193). IEEE.
- Sinha, S; Singh, T. N; Singh, V. K; & Verma, A. K. (2010). Epoch determination for neural network by self-organized map (SOM). *Computational Geosciences*, 14(2), 199-206.
- Sović, A; & Seršić, D. (2012). Signal decomposition methods for reducing drawbacks of the DWT. *Engineering Review*, 32(2), 70-77.
- Xian, L; He, K; Wang, C; & Lai, K. K. (2020). Factor analysis of financial time series using EEMD-ICA based approach. *Sustainable Futures*, 2(1), 100003.
- Xuan, Y; Yu, Y; & Wu, K. (2020, May). Prediction of short-term stock prices based on EMD-LSTM-CSI neural network method. In 2020 5th IEEE International Conference on Big Data Analytics (ICBDA) (pp. 135-139). IEEE.
- Yeh, J. R; Shieh, J. S; & Huang, N. E. (2010). Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method. *Advances in Adaptive Data Analysis*, 2(2), 135-156.
- You, K; Long, M; Wang, J; & Jordan, M. I. (2019). How does learning rate decay help modern neural networks?

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.

Zhang, X; Liang, X; Zhiyuli, A; Zhang, S; Xu, R; & Wu, B. (2019). At-lstm: An attention-based lstm model for financial time series prediction. In *IOP Conference Series: Materials Science and Engineering*, 569(5), 052037. IOP Publishing.

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.

