

بررسی عملکرد دو مدل پیشبینی قیمت سهام، مبتنی بر شبکه عصبی حافظه کوتاه مدت طولانی و با دو رویکرد متفاوت انتخاب ویژگی و تجزیه سری زمانی

کیوان حقیقی نائینی

کارشناسی ارشد، گروه مدیریت سیستم و بهره‌وری، دانشکده مهندسی صنایع، دانشگاه تربیت مدرس، تهران، ایران

keyvan_haghighi@modares.ac.ir

محمد علی رستگار¹

استادیار، گروه مدیریت سیستم و بهره‌وری، دانشکده مهندسی صنایع، دانشگاه تربیت مدرس، تهران، ایران

ma_rastegar@modares.ac.ir

چکیده

امروزه توسعه مدل‌های پیشبینی قیمت، با توجه به گسترش روز افزون بازارهای مالی از اهمیت بالایی برخوردار است. در این پژوهش دو مدل از ترکیب الگوریتم ژنتیک و الگوریتم تجزیه حالت متغیر به صورت جداگانه با شبکه عصبی LSTM ارائه شده است. در رویکرد انتخاب ویژگی، الگوریتم ژنتیک از میان تمام ویژگی‌های ورودی مدل، زیرمجموعه‌ای از ویژگی‌ها را انتخاب کرده و شبکه عصبی LSTM، با استفاده از ویژگی‌های منتخب، قیمت سهام را پیشبینی می‌کند. اما در رویکرد تجزیه سری زمانی، سری زمانی قیمت سهام به عنوان تنها ورودی مدل توسط الگوریتم VMD تجزیه شده و شبکه عصبی LSTM با پیشبینی توابع تولید شده و تجمیع نتایج، قیمت سهام را پیشبینی می‌کند. در این پژوهش قیمت 5 سهم بورس نیویورک را با دو مدل پیشنهادی، پیشبینی کرده و عملکرد آنها را مقایسه نموده‌ایم. نتایج تجربی، برتری مدل GA-LSTM را نسبت به سایر مدل‌های معیار نشان می‌دهد.

کلمات کلیدی: پیشبینی قیمت سهام، یادگیری عمیق، الگوریتم ژنتیک، انتخاب ویژگی، تجزیه سری زمانی.

¹ نویسنده مسئول

Investigating the performance of two stock price forecasting models, based on long short-term memory neural network and with two different approaches of feature selection and time series analysis

K. Haghighi Naeini, (corresponding author), keyvan_haghighi@modares.ac.ir

M.Sc. degree, Department of Systems and Productivity Management, Faculty of Industrial Engineering, Tarbiat Modares University, Tehran, Iran

MA. Rastegar, ma_rastegar@modares.ac.ir

Assistant Professor, Department of Systems and Productivity Management, Faculty of Industrial Engineering, Tarbiat Modares University, Tehran, Iran

Abstract

In the financial literature, the capital market plays an essential role in economic growth through the financing of enterprises, the optimal allocation of resources, the improvement of liquidity of assets, the improvement of company management and the increase of transparency in the economy. One of the most important challenges that shareholders always face in the market is to make the right decision and be in the right position with buying and selling stocks. Stock forecasting that predicts future stock movements and benefits shareholders has been an attractive research area for financial studies and researchers since the past. In this research, it presents two models of neural networks that receive inputs and predict price and movement trends, and finally, the performance of these two models is compared. The data studied in this research includes the price data of the 5 largest shares of the New York market during the years 2000 to 2020, in which 80 percent of the initial samples are used as training data and the remaining 20 percent are used as test data. In the proposed VMD-LSTM model, first, the stock price time series is decomposed using the variational mode decomposition algorithm (VMD) to the intrinsic mode functions (IMF), and then each of these IMFs is predicted by the LSTM model and After interpreting the results. In the second proposed method, available features including price and some of the most important technical indicators are used to predict stock prices. In the GA-LSTM model, genetic algorithm is first used to select the best features from the entire set of features. Then, the time series of the stock closing price was predicted by LSTM network using the selected features. The results of the research showed that because both models are very good in price prediction, the proposed GA-LSTM model, which is developed based on feature selection, has less error and more accurate performance.

Keywords: Stock price prediction, deep learning, genetic algorithm, feature selection, time series decomposition.

1. مقدمه

سرمایه‌گذاری در بازار سهام یک فعالیت محبوب و اغلب سودآور است که هم سهامداران مبتدی و هم متخصصان این حوزه از آن لذت می‌برند. سرمایه‌گذاران از استراتژی‌های مختلفی استفاده می‌کنند که در دوره نگهداری و خطرپذیری متفاوت هستند. پیشبینی عملکرد سهام، یک هدف مهم در دنیای مالی است، زیرا یک پیشبینی نسبتاً دقیق این امکان را برای سرمایه‌گذار فراهم می‌کند که همواره منافع مالی بالایی را به همراه داشته باشد و همچنین ریسک‌های بازار را پوشش دهد.

پیشبینی بازار سهام و توسعه مدل‌های معاملاتی سودآور یکی از مسائلی است که همواره مورد توجه پژوهش‌گران، تحلیلگران اقتصادی و معامله‌گران بازار سهام بوده است. با این حال، ارائه مدلی که تحت شرایط مختلف بازار، عملکرد قابل اعتمادی داشته باشد، بسیار چالش برانگیز است. در چند دهه گذشته، به لطف پیشرفت‌های کامپیوتری و فناوری اطلاعات، مدل‌های محاسباتی هوشمند به‌عنوان جایگزین‌های مناسب برای سیستم‌های تصمیم‌گیری سنتی شروع به ظهور کردند. مدل‌های قبلی عمدتاً مبتنی بر قوانین و تحلیل‌های ایستا بودند و به دلیل فعل و انفعالات دستی بیش از حد، این مدل‌ها از احساسات انسانی مصون نبوده و در نتیجه بازدهی ناسازگار و وضعی داشتند^[1]. از سوی دیگر، مدل‌های نو ظهور هوش مصنوعی مانند انواع مختلف شبکه‌های عصبی عملکرد مناسب‌تری در پیشبینی قیمت ارائه کردند و در نتیجه به سرعت مورد توجه پژوهشگران این حوزه قرار گرفته و مدل‌های ترکیبی بسیاری جهت پیشبینی قیمت سهام توسعه داده شد^[2].

در همین حال، عملکرد روش‌های یادگیری ماشین سنتی تا حد زیادی به طراحی ویژگی‌ها بستگی دارد، که این امر باعث تداخل خاصی در عملکرد پیشبینی می‌شود. این روش‌ها در فرآیند پیشبینی نیز ممکن است با مشکلاتی مانند بیش‌برازش و کندی همگرایی مواجه شوند^[3]. اخیراً، یادگیری عمیق، به‌عنوان یک نسخه پیشرفته از مدل‌های یادگیری ماشین سنتی، به دلیل عملکرد خوب آن در

حوزه‌هایی مانند تشخیص تصویر و تشخیص گفتار، توجه زیادی را در این زمینه به خود جلب کرده‌است. همچنین در زمینه پیشبینی مالی، یک شبکه عصبی عمیق امکان افزایش دقت پیشبینی بازار سهام را فراهم می‌کند. مهم‌ترین مزایای روش‌های یادگیری عمیق، یادگیری خودکار ویژگی‌ها، یادگیری چندلایه ویژگی‌ها، دقت بالا در نتایج، قدرت تعمیم بالا و شناسایی داده‌های جدید است^[4]. بنابراین، هدف این مطالعه ارائه مدل پیشبینی عملکرد سهام با استفاده از شبکه عصبی عمیق LSTM و الگوریتم ژنتیک جهت بهبود عملکرد سرمایه‌گذاری در بازار سهام می‌باشد.

2. ادبیات نظری و پیشینه پژوهش

قیمت سهام تحت تأثیر عوامل متعددی قرار می‌گیرد که به صورت مستقیم یا غیرمستقیم بر عرضه و تقاضا در بازار تأثیر می‌گذارند. یکی از مهم‌ترین عوامل، عملکرد شرکت است؛ شرکت‌های با سودآوری و رشد بالا معمولاً افزایش قیمت سهام را تجربه می‌کنند.

وضعیت اقتصادی مانند نرخ بهره، تورم و رشد اقتصادی نیز تأثیرات مهمی بر قیمت سهام دارند، زیرا این عوامل بر تصمیمات سرمایه‌گذاران اثر می‌گذارند. همچنین، رویدادهای سیاسی و جهانی نظیر بحران‌ها، جنگ‌ها یا تغییرات سیاست‌های دولتی می‌توانند نوسانات شدیدی در بازار ایجاد کنند.

اخبار و شایعات مرتبط با شرکت‌ها یا صنعت خاص نیز تأثیرگذار هستند؛ خبرهای مثبت یا منفی می‌توانند ارزش سهام را بالا یا پایین ببرند. سیاست‌های مالی و پولی دولت و بانک مرکزی، مانند تغییر در نرخ بهره یا مالیات‌ها، از دیگر عوامل مهمی هستند که بر قیمت سهام اثر می‌گذارند. در نهایت، وضعیت صنعت که یک شرکت در آن فعالیت می‌کند، نظیر تغییرات تکنولوژیکی، رقابت و مقررات، نقش مهمی در تعیین قیمت سهام آن شرکت دارد.

یادگیری عمیق² (DL) شاخه ای از یادگیری ماشین³ (ML) و هوش مصنوعی⁴ (AI) است که امروزه به عنوان هسته اصلی انقلاب صنعتی چهارم در نظر گرفته می شود. به دلیل قابلیت یادگیری از داده ها، فناوری DL از شبکه عصبی مصنوعی⁵ (ANN) نشأت گرفته است، به یک موضوع داغ در زمینه محاسبات و مدل سازی های ریاضی تبدیل شده است و به طور گسترده در زمینه های مختلف کاربردی مانند مراقبت های بهداشتی، تشخیص بصری، تجزیه و تحلیل متن، امنیت سایبری، پیشبینی بازارهای مالی، ریسک اعتباری و ... مورد استفاده قرار گرفته است.

روش کار این مدل ها بر اساس مجموعه ای از الگوریتم هایی است که سعی می کنند درک بالایی از داده ها را با استفاده از یک نمودار عمیق با لایه های پردازشی متعدد، متشکل از تبدیل های خطی و غیرخطی متعدد مدل سازی کند. فرآیند یادگیری ماشین با وارد کردن داده های آموزشی به الگوریتم مورد نظر آغاز می شود تا مدل پیشبینی نهایی طراحی شود. سپس داده های ورودی جدید به الگوریتم یادگیری ماشین وارد می شود و مقدار پیشبینی و نتایج با یکدیگر بررسی می شوند تا مشخص شود آیا مدل توسعه داده شده به درستی کار می کند یا خیر. اگر پیشبینی و نتایج مطابقت نداشته باشند، الگوریتم چندین بار آموزش داده می شود تا زمانی که به نتیجه مطلوب برسد. این امر به الگوریتم یادگیری ماشین امکان می دهد به طور مداوم یاد بگیرد و پاسخ بهینه را تولید کند و به تدریج دقت آن در طول زمان افزایش یابد^[5].

همان طور که گفته شد در سال های اخیر، روش های یادگیری ماشین و شبکه های عصبی مصنوعی به دلیل عملکرد بهترشان نسبت به مدل های اقتصادسنجی سنتی، به موضوع اصلی پژوهش های این حوزه و ابزاری کمکی برای پیشبینی سری های زمانی مالی بدل شده اند. تجزیه و تحلیل سری های زمانی برای پیشبینی مقادیر آینده بر اساس مقادیر مشاهده شده قبلی، یکی از بهترین ابزارها برای تحلیل روند و پیشبینی

آینده است. برای هر متغیری که در طول زمان تغییر می کند، می توان یک سری زمانی در نظر گرفت. سری زمانی مجموعه ای از نقاط داده است که به ترتیب در یک دوره زمانی رخ می دهند. بنابراین، هر مدل پیشبینی مبتنی بر داده های سری زمانی، زمان را به عنوان یک متغیر مستقل خواهد داشت و خروجی هر مدل سری زمانی مقدار یا طبقه بندی پیشبینی شده در یک زمان خاص خواهد بود. مهم ترین مثال سری های زمانی در دنیای سرمایه گذاری سری زمانی قیمت اوراق بهادار می باشد که در یک دوره زمانی مشخص و در فواصل زمانی معین قیمت سهام ثبت و ردیابی می شود. روش های پیشبینی با استفاده از سری های زمانی هم در تحلیل بنیادی و هم در تحلیل تکنیکال استفاده می شود. در ادامه به بررسی اجمالی تعدادی از این پژوهش ها می پردازیم:

آدیکاری و آگراوال^[6] مدلی را برای پیشبینی نرخ ارز و شاخص های قیمت سهام با ادغام یک مدل پیاده روی تصادفی و یک شبکه عصبی مصنوعی ایجاد کردند. نیو و وانگ^[7] در پژوهش دیگر یک شبکه عصبی شعاعی پایه (RBF) موثر در زمان داده تصادفی ایجاد کردند و قیمت نفت خام و شاخص های قیمت سهام را پیشبینی کردند. داس و همکاران^[8] یک مدل ترکیبی جدید SVM-TLBO را برای پیشبینی قیمت بسته شدن روزانه شاخص آتی کالا COMDEX که در چند بورس کالای هند معامله می شود، پیشنهاد کردند این مدل از یک ماشین بردار پشتیبانی (SVM) و یک بهینه سازی مبتنی بر یادگیری (TLBO) تشکیل شده است و عملکرد بهتر آن تایید شده است.

اگرچه شبکه های عصبی فوق عملکرد پیشبینی نسبتاً خوبی داشتند، اما دقت آنها در زمانی که سری های زمانی پویا و غیرخطی بودند، همچنان رضایت بخش نبود. با برقراری ارتباط بین واحدهای لایه پنهان، وابستگی داده ها در نقاط مختلف زمان را می توان با شبکه های عصبی بازگشتی⁶ (RNN) توضیح داد. ساختار داده مرتبط قبل و بعد، RNN ها را به شکل ویژه ای برای پیشبینی داده های سری

¹ Recurrent Neural Network

² Deep Learning
³ Machine Learning
⁴ Artificial intelligence
⁵ artificial neural network

زمانی مناسب می‌کند^[9] و ادبیات موضوع شاهد کاربرد گسترده آنها در پیشبینی سری‌های زمانی مالی بوده است. با این حال، اطلاعات تاریخی نگهداری شده در یک RNN با افزایش بازه زمانی افزایش می‌یابد و منجر به ناپدید شدن گرادیان یا افزایش ناگهانی گرادیان می‌شود و نتایج پیشبینی RNN را مخدوش می‌کند. با ظهور شبکه حافظه کوتاه مدت طولانی (LSTM) ساختار "سلول حافظه" برای جایگزینی واحدهای لایه پنهان RNN معرفی شد. هر سلول حافظه از یک مکانیزم "دروازه" ویژه تشکیل شده است که باعث می‌شود LSTM اطلاعات تاریخی مهم را حفظ و موارد بی اهمیت را فیلتر کند. بر اساس برتری ویژه مکانیزم شبکه عصبی LSTM، از این شبکه عصبی به طور گسترده در پیشبینی سری‌های زمانی و به ویژه برای پیشبینی سری زمانی قیمت سهام استفاده می‌شود. به عنوان مثال، دینگ و کین^[10] یک مدل شبکه عصبی عمیق بازگشتی مرتبط با چندین ورودی و خروجی مبتنی بر LSTM برای پیشبینی قیمت‌های چندگانه، از جمله بالاترین و پایین‌ترین قیمت سهام در روز معاملاتی به طور همزمان پیشنهاد کردند. در پژوهش لیو^[11] از الگوریتم LSTM برای پیشبینی نوسانات شاخص S&P 500 و سهم اپل استفاده شده است. در این مطالعه از داده‌های تاریخی برای آموزش و اعتبار سنجی مدل استفاده شده است.

با توجه به کاستی‌های مدل‌های تکی بکار رفته در پیشبینی داده‌های پیچیده، مدل‌های ترکیبی که دو یا چند مدل مجزا را ادغام می‌کنند برای حل مشکلاتی مانند دقت پایین مدل و پیشبینی‌های عقب‌افتاده پیشنهاد شده‌اند. به این ترتیب، روش‌های پیش‌پردازش مختلفی برای کاهش نویز یا بهینه سازی داده‌ها و فرآیند مدل معرفی می‌شوند و سپس داده‌های پردازش شده برای به دست آوردن نتیجه نهایی وارد مدل پیشبینی می‌شوند. در ادامه به بررسی مهم‌ترین پژوهش‌ها با رویکرد ترکیبی و مشابه با مدل پیشنهادی می‌پردازیم.

زنگ و همکاران^[12] در پژوهش خود یک مدل ترکیبی AGA-LSTM جهت پیشبینی قیمت سهام ارائه کردند سهم اصلی این مطالعه بهینه سازی مدل LSTM با استفاده از الگوریتم ژنتیک تطبیقی (AGA) است. مکانیزم بهینه سازی بر اساس رتبه بندی انفرادی با تنظیم خودکار ساختار شبکه مدل

و ترکیبی از فرآیندها، می‌تواند به طور قابل توجهی تعداد دفعات تکرار تنظیم هایپرپارامتر را کاهش دهد. طبق نتایج تحلیل انجام شده بر روی 6 شاخص مختلف بازار های سهام، مدل پیشنهادی در هر فرم عملکرد بهتری نسبت به LSTM و سایر مدل های یادگیری ماشین داشته است.

التوئیبی^[13] در پژوهشی دیگر یک مدل جدید پیشبینی بازار سهام را معرفی کرد که شامل سه فاز اصلی است: استخراج ویژگی، انتخاب ویژگی بهینه، و پیشبینی. در ابتدا، ویژگی‌های آماری مانند میانگین، انحراف معیار، واریانس، چولگی و کشیدگی و مهم‌ترین اندیکاتورهای تکنیکال از داده‌های جمع آوری شده بازار سهام استخراج می‌شود. برای به دست آوردن بهترین نتایج پیشبینی شده، انتخاب مرتبط ترین ویژگی‌ها توسط یک مدل ترکیبی جدید با نام (RDAWA) انتخاب می‌شود. در مرحله آخر پیشبینی قیمت سهام با استفاده از ویژگی‌های انتخاب شده با یک مدل طبقه‌بندی کننده شامل ماشین بردار پشتیبان (SVM)، جنگل تصادفی 1 (RF1)، جنگل تصادفی 2 (RF2) و شبکه عصبی بهینه شده (NN) صورت می‌گیرد. برای پیشبینی دقیق تر، آموزش شبکه NN توسط RDAWA پیشنهادی از طریق تنظیم دقیق وزن بهینه انجام می‌شود. در نهایت، عملکرد کار پیشنهادی نسبت به سایر مدل‌های مرسوم با توجه به معیارهای خاص مقایسه شده است.

چونگ و شین^[14] یک مدل پیشبینی قیمت مبتنی بر مدل ترکیبی GA-LSTM پیشنهاد کردند. در این مطالعه از الگوریتم ژنتیک جهت بهینه‌سازی پارامترهای الگوریتم LSTM استفاده شده است. به عبارت دیگر الگوریتم ژنتیک به جستجوی مقدار بهینه یا نزدیک به بهینه برای اندازه پنجره زمانی و تعداد واحدهای LSTM در یک شبکه می‌پردازد.

در پژوهش نیو و همکاران^[15] یک مدل ترکیبی VMD-LSTM جهت پیشبینی قیمت سهام ارائه شد. مدل پیشنهادی بر اساس الگوریتم تجزیه VMD که از طریق آن می‌توان سری پیچیده اصلی را به یک سری زیرمجموعه محدود تجزیه کرد ارائه شده است. زیرمجموعه‌های تجزیه‌شده توسط این الگوریتم توسط شبکه LSTM پیشبینی شده و نتیجه پیشبینی سری زمانی اصلی از تجمیع نتایج پیشبینی زیرمجموعه‌ها بدست آمده است.

نتایج، برتری مدل پیشنهادی را نسبت به مدل پایه و مدل‌های مبتنی بر الگوریتم تجزیه حالت تجربی (EMD) نشان می‌دهد.

کیو و همکاران [16] یک مدل پیشبینی جهت پیشبینی قیمت باز شدن سهام ارائه کردند. در این پژوهش ابتدا داده‌های سهام از طریق الگوریتم تبدیل موجک (WT) پردازش شده و سپس یک شبکه عصبی مبتنی بر توجه LSTM برای پیشبینی قیمت باز شدن سهام توسعه داده می‌شود.

در پژوهشی دیگر محمدعلی و همکاران [17] روش ترکیبی جدید پیشنهاد کردند که بر اساس نسخه‌ای بهبود یافته از روش تجزیه تجربی (EMD) و شبکه LSTM است. در این روش، ابتدا داده‌های نوبی سهام با استفاده از نسخه جدید EMD که از تکنیک درون‌یابی Akima به جای درون‌یابی مکعبی استفاده می‌کند، به چندین مؤلفه جدا به نام توابع مد ذاتی (IMF) تقسیم می‌شوند. سپس زیرمؤلفه‌های با همبستگی بالا برای ساخت مدل LSTM استفاده می‌شوند. این مدل ترکیبی با مدل‌های دیگر مثل LSTM ساده، ماشین بردار پشتیبان (SVM)، جنگل تصادفی و درخت تصمیم مقایسه شده و نتایج نشان می‌دهد که مدل پیشنهادی ترکیبی Akima-EMD-LSTM نسبت به سایر مدل‌ها عملکرد بهتری داشته و به عنوان یک مدل مؤثر برای پیش‌بینی داده‌های مالی پیچیده و غیرخطی توصیه می‌شود. چن و همکاران [18] در پژوهش خود یک رویکرد انتخاب ویژگی بر پایه LASSO با شبکه LSTM آبشاری (Ca-LSTM) ترکیب شده پیشنهاد کردند. ایده این مدل بر اساس بازسازی ویژگی‌های داده و تقویت تأثیر ویژگی‌های منفرد از طریق آبشاری‌سازی است. از طریق مقایسه جامع نتایج بدست آمده با مدل‌های رایج دیگر مانند LSTM، XGboost، SVR و VMD-LSTM در چهار مجموعه داده با ویژگی‌های مختلف، برتری مدل پیشنهادی، اثبات شده است. همچنین عنوان شد که هرچه دوره زمانی داده‌های استفاده‌شده برای پیش‌بینی کوتاه‌تر باشد و نوسانات سهام کمتر باشد، مدل عملکرد بهتری دارد. همچنین، زمانی که شبکه LSTM آبشاری در مؤلفه‌هایی که توسط شبکه VMD تولید شده‌اند به کار گرفته می‌شود، عملکرد بهتری نسبت به روش‌های مرجع دارد.

در پژوهشی دیگر گولمز [19] یک شبکه LSTM جدید را که توسط الگوریتم بهینه‌سازی خرگوش مصنوعی (ARO) بهینه شده، پیشنهاد می‌کند. این مدل با نام LSTM-ARO معرفی شده و از داده‌های قیمت سهام شاخص DJIA برای پیش‌بینی استفاده می‌کند. در این مدل داده‌ها به فرم جدیدی تبدیل شده‌اند که از 20 روز گذشته برای پیش‌بینی قیمت روز بعد استفاده می‌کند. در این مدل یک شبکه LSTM جدید با پارامترهای مختلف ایجاد شده و این پارامترها به متغیرهای الگوریتم ARO متصل شده‌اند. تغییر متغیرها باعث تغییر در معماری LSTM می‌شود و الگوریتم ARO بهترین معماری را برای دستیابی به نتایج بهینه پیدا می‌کند. برای ارزیابی کیفیت مدل پیشنهادی، این مدل با شبکه‌های LSTM1D، LSTM2D، LSTM3D، ANN و LSTM-GA مقایسه شده است. نتایج نشان می‌دهد که مدل LSTM-ARO بهترین عملکرد را در میان این مدل‌ها دارد و پیش‌بینی‌های بسیار دقیقی ارائه می‌دهد.

نصیری و عبادزاده [20] در مطالعه خود دو روش جدید برای پیش‌بینی چندمرحله‌ای قیمت سهام بر اساس دو تکنیک مختلف تجزیه یعنی تبدیل خطی کسینوسی گسسته (DCT) و تبدیل غیر خطی تجزیه حالت‌های متغیر (VMD) ارائه کردند. روش DCT-MFRFNN بر اساس DCT و شبکه عصبی فازی بازگشتی چندمنظوره (MFRFNN) طراحی شده و از DCT برای کاهش نوسانات سری‌های زمانی و ساده‌سازی ساختار آن استفاده می‌کند و MFRFNN برای پیش‌بینی قیمت سهام به کار گرفته می‌شود. روش VMD-MFRFNN که مبتنی بر VMD و MFRFNN است، مزایای هر دو را با هم ترکیب می‌کند VMD-MFRFNN از دو مرحله تشکیل شده است: در مرحله تجزیه، سیگنال ورودی به چندین تابع حالت ذاتی (IMF) توسط VMD تجزیه می‌شود. در مرحله پیش‌بینی، هر IMF به یک MFRFNN جداگانه داده می‌شود و سیگنال‌های پیش‌بینی‌شده برای بازسازی خروجی نهایی جمع می‌شوند.

نتایج تجربی نشان داد که VMD-MFRFNN عملکرد بهتری نسبت به سایر روش‌های پیشرفته داشته و همچنین، DCT-MFRFNN در تمامی آزمایش‌ها عملکرد بهتری نسبت به

MFRFNN و DCT-LSTM داشته که تأثیر مثبت DCT بر عملکرد MFRFNN را نشان می‌دهد.

با بررسی پژوهش‌های انجام شده و همانطور که قابل مشاهده است، در تحقیقات خارجی و داخلی با گذر زمان، روش‌های یادگیری عمیق جایگزین روش‌های سنتی یادگیری ماشین در مدل‌های پیشنهادی شده‌اند. همانطور که پیشتر گفته شد مطالعات مورد بررسی در این پژوهش در دو دسته کلی مدل‌های پیشبینی مبتنی بر رویکرد تجزیه و همچنین مدل‌های پیشبینی مبتنی بر رویکرد انتخاب ویژگی قرار می‌گیرند. در مدل‌های مبتنی بر رویکرد تجزیه، از یک الگوریتم تجزیه در ترکیب با مدل پیشبینی اصلی استفاده می‌شود. پژوهش‌های انجام شده در این حوزه به مرور زمان و با ظهور الگوریتم‌های تجزیه جدید به روز شده و نتایج این مدل‌ها نیز بهبود یافته‌اند. به طور کلی پژوهش‌های این حوزه اکثراً از الگوریتم‌های مشهور EMD و WT در مدل‌های خود استفاده کرده‌اند، در حالی که در سال‌های اخیر الگوریتم‌های تجزیه جدید تری مانند EEMD، CEEMD و VMD معرفی شده‌اند و کمتر در مدل‌های پیشبینی استفاده شده است. بنابراین یکی از اهداف این پژوهش مقایسه عملکردی الگوریتم‌های تجزیه جدید با الگوریتم‌های تجزیه EMD و WT می‌باشد. اما با بررسی پیشینه پژوهش‌های دسته دوم یعنی پژوهش‌های مرتبط یا رویکرد انتخاب ویژگی که از ترکیب یک الگوریتم فراابتکاری در ترکیب با یک مدل پیشبینی توسعه می‌یابند، می‌توان گفت که این پژوهش‌ها نسبت به حوزه مبتنی بر تجزیه سری زمانی جدید تر است. به طوری که با مرور ادبیات می‌توان دریافت که از الگوریتم‌های فراابتکاری پیشتر و اکثراً در بهینه‌سازی هایپر پارامترهای مدل استفاده شده و استفاده از این الگوریتم‌ها، جهت انتخاب ویژگی در پژوهش‌های جدید تر معرفی و استفاده شده است. بررسی پژوهش‌های این دو حوزه نشان می‌دهد که در این پژوهش‌ها جهت بررسی کارایی مدل‌ها، نتایج پیشبینی با نتایج مدل‌های معیار و مدل‌های متشکل از سایر الگوریتم‌های مشابه، مقایسه شده است. به طور مثال مدل‌های مبتنی بر تجزیه با مدل‌های

تجزیه دیگر مقایسه شده و در واقع عملکرد الگوریتم‌های تجزیه متفاوت بررسی و مقایسه شده‌اند و یا در مدل‌های مبتنی بر انتخاب ویژگی، عملکرد الگوریتم‌های فراابتکاری متفاوت در انتخاب ویژگی مقایسه شده‌اند. اما هدف اصلی این پژوهش مقایسه کلی تر این پژوهش‌ها و در واقع مقایسه دو رویکرد متفاوت در پیشبینی قیمت است که پیشتر در هیچ پژوهشی انجام نگرفته و می‌تواند فارغ از الگوریتم‌های مختلف تجزیه و یا انتخاب ویژگی، رویکرد برتر در پیشبینی قیمت سهام را معرفی کند.

3. روش‌شناسی تحقیق

در ادامه رویکردهای الگوریتم ژنتیک و شبکه LSTM و معیارهای خطا را معرفی کرده و چارچوب اصلی مدل ترکیبی پیشنهادی را ارائه می‌کنیم. سپس در بخش بعدی، نتایج پیشبینی تجربی قیمت سهام را که با استفاده از مدل پیشنهادی به دست آمده را ارائه کرده و با نتایج مدل پایه مقایسه می‌کنیم.

1.3. شبکه عصبی کوتاه مدت طولانی (LSTM)

مدت کوتاهی پس از آموزش اولین شبکه‌های عصبی بازگشتی با استفاده از الگوریتم پس‌انتشار، مشکلات یادگیری وابستگی‌های بلندمدت به دلیل ناچیز شدن و یا رشد انفجاری گرادیان، مورد توجه قرار گرفت. یکی از اولین و موفق‌ترین تکنیک‌ها برای حل مشکل گرادیان‌های ناپدید شونده در قالب مدل حافظه کوتاه مدت طولانی (LSTM) به وسیله هوکرایتر⁷ و اشמיד هابر⁸ در سال 1997 ارائه شد. LSTM‌ها بسیار شبیه به شبکه‌های عصبی بازگشتی استاندارد هستند، اما در این مدل هر گره معمولی بازگشتی با یک سلول حافظه جایگزین می‌شود و هر سلول حافظه حاوی یک حالت داخلی است^[21].

همانطور که اشاره شد در شبکه‌های LSTM یک سلول حالت وجود دارد که وظیفه آن حفظ و انتقال اطلاعات مهمی

^۷ Hochreiter

^۸ Schmidhuber

است بازه مقادیر سلول را تغییر دهد. همچنین یک تابع سیگموئید بر روی ترکیبی از خروجی لایه پنهان قبلی و ورودی این مرحله اعمال کرده و در نهایت خروجی سیگموئید را در خروجی \tanh ضرب کرده و نتیجه نهایی بدست خواهد آمد روابط مطابق روبه رو خواهد بود:

$$o_t = \sigma(W_a * [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

2.3. الگوریتم ژنتیک (GA)

الگوریتم ژنتیک در واقع از نظریه تکامل داروین الهام گرفته شده است و کاربردهای بسیار زیادی در یافتن جواب مسائلی از قبیل بهینه سازی، مکان یابی و ... دارد. یکی از نقاط قوت این الگوریتم سرعت بالای آن در حرکت به سمت جواب مسأله است که باعث شده در مسائلی که فضای جواب بسیار وسیعی دارند و بررسی تمام جوابها عملاً غیر ممکن است، بسیار مورد استفاده قرار بگیرد. از دیگر ویژگیهای مثبت این الگوریتم می توان به جست و جوی همزمان در چندین جهت و همچنین عدم نیاز به ویژگیهای تحدب و پیوستگی تابع هدف مسأله اشاره کرد.

شیوه کار این الگوریتم به بیان ساده به این شکل است که الگوریتم با مجموعه ای از از نقاط نامزد کار خود را آغاز کرده و با استفاده از عملگرهای ژنتیکی در جهت یافتن پاسخ بهتر پیش می رود.

هر کروموزوم در الگوریتم یک نقطه در فضای جست و جوی جواب یا به عبارت دیگر یک راه حل مسأله را نشان می دهد. کروموزومها از مجموعه ای از ژن ها تشکیل شده و مجموعه ای از کروموزومها که با کدهای باینری نمایش داده می شوند یک جمعیت را تشکیل می دهند. شیوه کار الگوریتم معمولاً به این صورت است که با تولید جمعیتی از کروموزومها آغاز می شود. در گام بعدی کروموزومهای ساخته شده بررسی و ارزیابی می شوند و کروموزومهایی که با توجه به تابع هدف مسأله پاسخ بهینه تری تولید می کنند شانس بیشتری برای تولید مثل پیدا می کنند [23].

این الگوریتم تا جایی ادامه می یابد که جمعیت همگرا شده باشد به این معنی که الگوریتم فرزندان که تفاوت قابل

است که باید در حافظه شبکه باقی بماند. این اطلاعات در گذر از هر مرحله ممکن است تغییر کنند و اطلاعاتی به آنها اضافه یا از آنها کاسته شود که این عمل توسط عملگرهای ضرب و جمع انجام می شود و در نتیجه آن خطای محاسباتی مدل در عمق بسیار زیاد شبکه نیز منتشر می شود و مشکل کاهش شدید گرادیان در این مدل اتفاق نمی افتد [22].

اما تفاوت اصلی بین شبکه LSTM و RNN ها این است که در شبکه های LSTM گیت هایی شامل گیت فراموشی، گیت ورودی و گیت خروجی وجود دارد. گیت ها همچون دروازه هایی هستند که اجازه عبور اطلاعات را در اختیار دارند و با توابعی همچون سیگموئید و عملیات ریاضی مختلف ساخته می شوند. تابع سیگموئید بر روی ترکیب خروجی لایه مخفی قبل و ورودی مرحله جدید اعمال می شود و در نهایت مقداری بین صفر و یک را برمی گرداند که میزان حفظ یا حذف اطلاعات را تعیین می کند و در رابطه (1) نشان داده شده است.

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

در قدم بعدی علاوه بر اعمال تابع سیگموئید، تابع \tanh هم بر ترکیبی از خروجی لایه پنهان مرحله قبل و ورودی این مرحله اعمال می شود تا دانش و اطلاعات جدیدی را بسازد اما این نکته که چند درصد از این اطلاعات برای مرحله بعد لازم است حفظ شود، توسط تابع سیگموئید تعیین می شود و سپس این اطلاعات به سلول حالت اضافه می شود. روابط (2) و (3) نشان دهنده این فرآیند است:

$$i_t = \sigma(w_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\dot{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3)$$

سلول حالت طبق رابطه (4) به روز رسانی می شود:

$$C_t = f_t * C_{t-1} + i_t * \dot{C}_t \quad (4)$$

در مرحله آخر، برای تولید خروجی یک تابع \tanh را بر روی اطلاعات سلول وضعیت اعمال می کنیم تا مقادیر بین 0 تا 1 ایجاد شود چرا که جمع کردن اطلاعات در هر مرحله ممکن

سپس معادلات اویلر-لاگرانژ به راحتی در حوزه فرکانس به دست آمده و حل می‌شوند:

$$\widehat{f}(\omega) = \frac{\widehat{f}_0}{1 + \alpha\omega^2} \quad (10)$$

که در این رابطه $\widehat{f}(\omega)$ تبدیل فوریه f است و α نشان‌دهنده واریانس نوفه سفید است. برای ارزیابی پهنای باند یک حالت، مسئله تغییرات محدود به صورت زیر فرموله می‌شود که در آن $\{u_k\} = \{u_1, \dots, u_k\}$ مجموعه IMF ها، $\{\omega_k\} = \{\omega_1, \dots, \omega_k\}$ مجموعه فرکانس های مرکزی و عبارت $(\sigma(t) + \frac{j}{\pi t}) * u_k(t)$ تبدیل هیلبرت u_k را نشان می‌دهد.

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[(\sigma(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (11)$$

$$\sum_k u_k = f \text{ s.t.}$$

برای به حداقل رساندن معادله گفته شده، از تابع لاگرانژ تقویت شده با معرفی یک جمله جریمه درجه دوم و ضریب لاگرانژی λ استفاده می‌شود:

$$L(\{u_k\}, \{\omega_k\}, \lambda) := \alpha \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (12)$$

نتیجه نهایی با به روز رسانی فرکانس مرکزی و پهنای باند هر IMF در یک دنباله بهینه‌سازی به نام (ADMM) به دست می‌آید. روش به روز رسانی فرکانس را می‌توان به صورت رابطه (13) بیان کرد:

$$\widehat{u}_k^{n+1}(\omega) = \frac{\widehat{f}(\omega) - \sum_{i \neq k} \widehat{u}_i(\omega) + \widehat{\lambda}(\omega) / 2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (13)$$

توجهی با نسل قبلی داشته باشند تولید نکنند. در این مرحله عنوان می‌شود که الگوریتم مجموعه‌ای از پاسخ‌ها را برای مساله ارائه کرده است.

3.3 تکنیک تجزیه حالت متغیر

تکنیک تجزیه حالت متغیر (VMD) یکی از جدیدترین تکنیک‌های تجزیه سیگنال و مشابه روش تجزیه حالت تجربی (EMD) می‌باشد که برای اولین بار توسط دراگومیرتسکی و زوسو در سال 2014 ارائه شد [24]. این روش در واقع یک سیگنال نامانا را به توابع حالت ذاتی چندگانه تجزیه می‌کند. بنابراین، VMD برای پرداختن به داده های پیچیده‌ای مانند سری‌های زمانی مالی مناسب‌تر است و به طور گسترده ای برای پیاده‌سازی تجزیه سیگنال‌های چند فرکانسی به صورت تطبیقی استفاده شده است، که در آن باند فرکانس را می‌توان به طور همزمان تخمین زد تا به طور موثر خطاها را بین باندهای فرکانسی مختلف متعادل کند. این روش با الهام از روش EMD فرض می‌کند که سیگنال اصلی f از تعدادی توابع حالت ذاتی (IMF)، که در معادله (7) با u_k نشان داده شده است، تشکیل شده است:

$$f(t) = \sum_k u_k(t) \sum_k A_k(t) \cos[\varnothing_k(t)] \quad (7)$$

در این رابطه A_k عبارت است از دامنه آنی u_k و $\varnothing_k(t)$ عبارت است از فاز آنی u_k و فرکانس مرکزی هر IMF نیز با فرکانس لحظه‌ای آن طبق رابطه (2) در نظر گرفته می‌شود:

با شروع یک مساله حذف نویز رایج، سیگنال مشاهده شده f به صورت رابطه (8) فرموله می‌شود که در آن f سیگنال اصلی و η یک افزونه نوفه سفید است:

$$f_0 = f + \eta \quad (8)$$

برای بازیابی سیگنال اصلی f از تنظیم Tikhonov برای به حداقل رساندن f استفاده می‌شود:

$$\min_f \left\| f - f_0 \right\|_2^2 + \alpha \left\| \partial_t f \right\|_2^2 \quad (9)$$

مقداردهی اولیه تصادفی جمعیت. جمعیت الگوریتم ژنتیک با pop نشان داده شده است:

$$pop = \begin{pmatrix} a_{11} & \dots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{m1} & \dots & a_{mk} \end{pmatrix} \quad (16)$$

در ماتریس رابطه (16) هر ردیف یک کروموزوم (یا مجموعه ویژگی) را نشان می‌دهد، طول کروموزوم (k) تعداد کل ویژگی‌ها را نشان می‌دهد که در این پژوهش برابر با 25 در نظر گرفته شده است. مقدار m اندازه جمعیت را نشان می‌دهد که در این پژوهش برابر با 100 در نظر گرفته شده است. همچنین a_{ij} ها یکی از دو مقدار 0 و 1 را نشان می‌دهند که مقدار 1 نشان‌دهنده انتخاب و مقدار 0 نشان‌دهنده عدم انتخاب هر ویژگی است.

در گام بعدی از روش رولت برای عملیات انتخاب استفاده می‌شود و تناسب هر کروموزوم در جمعیت محاسبه می‌شود، احتمال انتخاب هر فرد به نسبت تناسب کروموزوم‌ها است و مجموع احتمال انتخاب کروموزوم 1 است. در طول الگوریتم، جمعیت یک بار در هر دور با توجه به احتمال به روزرسانی می‌شود.

در گام بعد برای انجام عملیات متقاطع از روش تقاطع چند نقطه‌ای⁹ استفاده شده و کروموزوم‌ها بین دو فرد با احتمال متقاطع 0,8 رد و بدل خواهند شد. در فرآیند الگوریتم، یک عملیات متقاطع بر روی هر کروموزوم در هر چرخه انجام می‌شود و روش تولید یک احتمال تصادفی است که اگر مقدار آن کمتر از احتمال متقاطع باشد، تعویض انجام می‌شود و در غیر این صورت تعویضی صورت نمی‌گیرد.

در گام آخر این الگوریتم از روش جهش بیت پایه¹⁰ برای انجام عملیات جهش استفاده شده است. در فردهای معاصر، با احتمال کمی یک ژن تغییر می‌کند. احتمال تغییر برابر با 0,02 تنظیم شده است. الگوریتم در هر دور یک احتمال تصادفی تولید می‌کند. اگر احتمال تصادفی کمتر از احتمال تلاقی

در این رابطه $\hat{u}_k^{n+1}(\omega)$ و $\hat{f}(\omega)$ و $\hat{\lambda}(\omega)$ عبارت اند از تبدیل‌های فوریه عبارت‌های u_k^{n+1} و $f(t)$ و $\lambda(\omega)$. معادله بالا را می‌توان به عنوان یک فیلتر وینر شناسایی کرد که در آن $\hat{u}_k^{n+1}(\omega)$ خروجی فیلتر $\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega) / 2$ با سیگنال قبل از مرکز u_k با روش گرانش طیف توان مجدداً تخمین زده می‌شود. معادلات به روز شده ω_k^{n+1} عبارتند از:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (14)$$

فرآیند VMD زمانی متوقف می‌شود که خطای نسبی e کمتر از حد همگرایی ϵ باشد:

$$e = \frac{\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \epsilon \quad (15)$$

3.3. تشریح مدل‌های پیشنهادی

در این پژوهش یک مدل پیشبینی قیمت سهام دو مرحله‌ای با ترکیب شبکه عصبی حافظه کوتاه مدت طولانی و الگوریتم ژنتیک و با رویکرد انتخاب ویژگی پیشنهاد می‌شود که در ادامه به شرح مراحل این مدل می‌پردازیم:

مرحله اول: در ابتدا با استفاده از الگوریتم ژنتیک به انتخاب ویژگی‌های با اهمیت می‌پردازیم. جهت دسترسی به مهم‌ترین ویژگی‌ها برای پیشبینی هر سهم، گام‌های زیر به ترتیب انجام می‌شود:

Multi point Crossover⁹

Bit Flip Mutation¹⁰

باشد، جهش انجام می‌شود؛ در غیر این صورت، جهش صورت نمی‌گیرد.

مراحل 2 تا 4 الگوریتم 100 بار تکرار می‌شود و در پایان الگوریتم، جمعیت بهینه نزدیک به راه حل بهینه تولید می‌شود. پارامترهای الگوریتم ژنتیک در مدل پیشنهادی در جدول (1) ارائه شده است:

جدول 1. مقادیر پارامترهای الگوریتم ژنتیک

ردیف	نام پارامتر	مقدار پارامتر
1	اندازه کروموزوم	25
2	اندازه جمعیت	100
3	نرخ متقاطع	0,8
4	نرخ جهش	0,02
5	تکرار الگوریتم	100
6	تابع برازندگی	MSE

مرحله دوم

ویژگی‌های انتخاب شده توسط الگوریتم ژنتیک در مرحله قبل به عنوان ویژگی‌های ورودی مدل LSTM در نظر گرفته می‌شوند و پیشبینی قیمت بسته شدن سهم در روز آتی با استفاده از این ویژگی‌های ورودی انجام می‌شود. مقادیر هایپر پارامترهای شبکه LSTM در مدل پیشنهادی، در جدول شماره (2) ارائه شده است.

جدول 2. مقادیر پارامترهای شبکه عصبی LSTM

ردیف	نام پارامتر	مقدار پارامتر
1	اندازه گام مدل	4
2	تعداد نورون لایه پنهان	300
3	احتمال حذف تصادفی	0,2
4	تابع فعال سازی	Relu
5	تابع بهینه ساز	Adam
6	اندازه دسته	256
7	تعداد تکرار مدل	100

مرحله سوم

برای ارزیابی کیفیت پیشبینی یک مدل توسعه یافته معمولاً چندین معیار عملکرد استفاده می‌شود. در این پژوهش، از معیارهای میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) برای ارزیابی دقت پیشبینی استفاده می‌شود. معیارهای گفته شده به ترتیب به صورت زیر محاسبه می‌شود:

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (17)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (18)$$

در عبارات بالا y_t نشان دهنده مقدار واقعی، \hat{y}_t نشان دهنده مقدار پیشبینی شده مدل و n برابر است با تعداد نمونه. به طور کلی، هرچه مقادیر MAE ، $RMSE$ و MSE کوچکتر باشند، فاصله بین مقدار پیشبینی شده و مقدار واقعی کمتر خواهد بود و به عبارت دیگر، دقت پیشبینی مدل بالاتر است.

4.3. ویژگی‌های استفاده شده در مدل پیشنهادی

در مدل پیشنهادی برای 5 سهم مورد نظر مقادیر 25 ویژگی که شامل اطلاعات قیمتی و تعدادی از مهم ترین اندیکاتورهای تحلیل تکنیکال است محاسبه شده و جهت انتخاب مهم ترین ویژگی‌ها در پیشبینی قیمت هر سهم، به عنوان ورودی به الگوریتم ژنتیک وارد شده و از لیست ویژگی‌های منتخب این الگوریتم در مرحله دوم برای پیشبینی قیمت سهام، استفاده می‌شود. در ادامه و در جدول (3) لیست این 25 ویژگی آورده شده است.

را با عنوان VMD-LSTM توسعه دادیم. در ادامه به شرح مراحل مدل می‌پردازیم:

مرحله 1: تکنیک VMD برای تجزیه سری زمانی اصلی قیمت سهام به K زیرمجموعه مستقل متقابل استفاده می‌شود. که با $IMF_1, IMF_2, \dots, IMF_k$ نشان داده می‌شوند، که نشان‌دهنده نوسان‌های جزئی مختلف قیمت از فرکانس بالا تا فرکانس پایین است، یعنی سری زمانی قیمت بر حسب IMF ها به صورت رابطه (19) بازسازی می‌شود:

$$x(t) = \sum_{k=1}^k IMF_k(t) \quad (19)$$

جهت کاهش تأثیر نوسانات و تسهیل بهینه‌سازی فرآیند حل، هر IMF به‌دست‌آمده از الگوریتم VMD در محدوده $[0, 1]$ نرمالایز شده و سپس هر سری IMF نرمالایز شده به عنوان ویژگی جدید ورودی مدل LSTM در نظر گرفته می‌شود.

مرحله 2: هر جزء IMF بدست آمده توسط VMD به مجموعه داده‌های آموزشی و آزمایشی با یک نسبت ثابت تقسیم می‌شود و مجموعه‌های ورودی و خروجی بر اساس اندازه گام تقسیم می‌شوند. شبکه LSTM برای آموزش و ساخت مدل پیشبینی بر اساس مجموعه داده آموزشی استفاده می‌شود که در آن پارامترهایی از جمله نرخ یادگیری، اندازه دسته، تعداد تکرارها و تعداد لایه‌های پنهان وجود دارد که برای اطمینان از دقت پیشبینی مدل حیاتی هستند و باید از قبل تنظیم شوند. لیست پارامترهای گفته شده و مقادیر آنها در جدول (4) ارائه شده است. اندازه گام در هر دو مدل با استفاده از نتایج آزمایش‌های تکراری با گام‌های متنوع بدست آمده و روی مقدار 4 تنظیم شده است، به این معنی که هم در مجموعه آموزشی و هم در مجموعه تست، مقدار پیشبینی را می‌توان بر اساس ورودی نقاط داده چهار مرتبه قبلی به دست آورد.

جدول 3. ویژگی‌های مورد استفاده در مدل GA-LSTM

ردیف	نام پارامتر	مقدار پارامتر
1	High	بالاترین قیمت سهم در روز معاملاتی
2	Low	پایین‌ترین قیمت سهم در روز معاملاتی
3	Open	قیمت باز شدن سهم در روز معاملاتی
4	TP ¹¹	قیمت تیبیکال
5	Adj Close	قیمت بسته شدن تعدیل شده سهم در روز معاملاتی
6	Volume	حجم معاملات سهم در روز معاملاتی
7	SMA(5)	میانگین متحرک ساده 5 روزه
8	SMA(20)	میانگین متحرک ساده 20 روزه
9	SMA(50)	میانگین متحرک ساده 50 روزه
10	EMA(10)	میانگین متحرک نمایی 10 روزه
11	EMA(20)	میانگین متحرک نمایی 20 روزه
12	EMA(100)	میانگین متحرک نمایی 100 روزه
13	MACD	خط مکدی
14	Signal_line	خط سیگنال
15	ATR	اندیکاتور ATR
16	ROC	اندیکاتور ROC
17	RSI	اندیکاتور RSI
18	SO%K	اندیکاتور استوکاستیک
19	William%R	اندیکاتور ویلیامز
20	Lower_Band	باند پایینی اندیکاتور باند بولینگر
21	Upper_Band	باند بالایی اندیکاتور باند بولینگر
22	SD20	اندیکاتور انحراف معیار 20 روزه قیمت
23	MOM	اندیکاتور مومنتوم
24	SnP_Close	مقدار پایانی شاخص S&P500 در روز معاملاتی
25	DJIA_Close	مقدار پایانی شاخص داوجونز در روز معاملاتی

با توجه به عملکرد خوب الگوریتم تجزیه VMD و شبکه عصبی LSTM، ما در این پژوهش مدل ترکیبی نوآورانه دوم

¹¹ TP = (High+Low+Close)/3

20 درصد باقیمانده به عنوان داده‌ی آزمایشی استفاده شده است.

در جدول (5) ویژگی‌های منتخب هر سهم و در جدول (6) نتایج مدل GA-LSTM که با استفاده از رویکرد انتخاب ویژگی و با 25 ویژگی گفته شده، توسعه داده شد، با نتایج مدل پیشنهادی دوم یعنی مدل VMD-LSTM که با استفاده از تجزیه سری زمانی ویژگی قیمت بسته شدن سهام، توسعه داد شده مقایسه شده است. علاوه بر این، نتایج دو مدل پیشنهادی، با نتایج سایر مدل‌های معیار نیز مقایسه شده است که در جدول (7) قابل مشاهده است.

همانطور که از جدول (6) برمی‌آید، علی‌رغم عملکرد مناسب و خطای کم هر دو مدل پیشنهادی، مدل GA-LSTM که مبتنی بر انتخاب ویژگی توسعه داده شده است در 4 سهم از 5 سهم مورد بررسی، با توجه به تمام معیارهای خطای گزارش شده، نتایج دقیق‌تری ارائه کرده است و مدل VMD-LSTM نیز در پیشبینی قیمت سهم جانسون اند جانسون (JNJ) نسبت به مدل دیگر عملکرد بهتری داشته است.

همچنین نتایج جدول (7) نشان می‌دهد که مدل مبتنی بر الگوریتم ژنتیک نسبت به دو مدل EMD-LSTM و WT-LSTM نیز عملکرد بهتری داشته و توانایی پیشبینی را در مقایسه با مدل منفرد بسیار افزایش می‌دهد از نتایج می‌توان استنباط کرد که رویکرد انتخاب ویژگی می‌تواند علاوه بر کاهش عملیات مدل با استفاده از ویژگی‌های کمتر، دقت مدل را نیز به شکل چشمگیری افزایش دهد. به عنوان مثال در تصویر (1)، نمودار سمت چپ نتیجه پیشبینی مدل GA-LSTM و نمودار سمت راست نتیجه مدل VMD-LSTM را در پیشبینی قیمت سهم یونایتد هلث نشان می‌دهد.

در ادامه به منظور بررسی معناداری تفاوت نتایج دو مدل پیشنهادی، از معیار MAE در آزمون دیبولد-ماریانو¹² بهره برده ایم. این آزمون نشان می‌دهد که قدرت پیشبینی یکسان تحت فرضیه $DM \sim N(0,1)$ است. بنابراین،

جدول 4. تنظیمات شبکه عصبی LSTM

ردیف	نام پارامتر	مقدار پارامتر
1	گام مدل	4
2	تعداد لایه شبکه	3
3	تعداد نورون لایه پنهان	300
4	درصد احتمال حذف تصادفی	0,2
5	تابع فعال سازی	Relu
6	تابع بهینه ساز	Adam
7	اندازه دسته	512
8	تعداد تکرار مدل	80

مرحله 3: نتیجه پیشبینی نهایی سری زمانی قیمت سهام اصلی با تجمیع خروجی‌های پیشبینی شده جداگانه هر IMF به دست می‌آید. در میان زیرمجموعه‌ها، IMF‌های با بسامد پایین معمولاً از مقادیر بزرگی تشکیل شده‌اند که نشان دهنده روند اصلی سری زمانی است. از منظر سطح دقت پیشبینی، خطاهای پیشبینی IMF‌های با بسامد پایین، نسبت به خطای پیشبینی IMF‌های با بسامد بالا، تأثیر مهم‌تری بر نتیجه پیشبینی نهایی خواهد داشت.

مرحله 4: در مرحله آخر، عملکرد این مدل نیز با معیارهای میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) ارزیابی می‌شود.

4. یافته‌های پژوهش

همانطور که پیشتر گفته شد، در این پژوهش از داده‌های قیمتی بازه‌های روزانه 5 سهم بزرگ بازار بورس نیویورک، شامل گلدمن ساکس (GS)، یونایتد هلث (UNH)، جی پی مورگان (JPM)، آی بی ام (IBM) و جانسون اند جانسون (JNJ) استفاده کرده‌ایم. بازه تاریخی مورد بررسی هر سهم از تاریخ 2001/01/01 تا 2020/01/01 و به استثناء روزهای تعطیل می‌باشد. از 80 درصد داده‌های ابتدایی نمونه به عنوان داده‌ی آموزشی و از

¹² Diebold-Mariano

بیشتر بوده و دیبولد - ماریانو صحت این مقایسه را تأیید می- کند.

فرضیه قدرت پیشبینی یکسان در سطح 95 درصد زمانی که $|DM| > 1.96$ باشد رد می شود. آزمون فوق برای خطای پیشبینی مدل VMD-LSTM و مدل GA-LSTM به کار برده شد و $DM = 2.217$ به دست آمد. بنابراین، همانطور که از نتایج پیداست، در سطح اطمینان 95 درصد قدرت پیشبینی مدل GA-LSTM

جدول 5. لیست ویژگی های منتخب هر سهم



ردیف	نماد	لیست ویژگی های منتخب
1	یونایتد هلث (UNH)	['High', 'Low', 'Volume', 'MACD', 'Adj Close', 'WT', 'ROC', 'EMA(10)', 'mom', 'RSI', 'atr', 'SnP_Close']
2	گلدمن ساکس (GS)	['Adj Close', 'MA(50)', 'High', 'Low', 'Signal Line', 'MA(5)', 'ROC', 'sd(20)', 'atr', 'MACD', 'EMA(20)', 'RSI']
3	آی بی ام (IBM)	['High', 'Low', 'Signal Line', 'WT', 'MA(5)', 'SMA', 'sd(20)', 'atr', 'MACD', 'EMA', 'RSI']
4	جی پی مورگان (JPM)	['upper_band', 'lower_band', 'Low', 'Signal Line', 'WT', 'MA(5)', 'EMA(10)', 'mom', 'RSI', 'atr']
5	جانسون اند جانسون (JNJ)	['Open', 'High', 'Low', 'Signal Line', 'Adj Close', 'STOK', 'ROC', 'EMA(10)', 'RSI', 'atr']

جدول 6. مقایسه نتایج دو مدل پیشنهادی

ردیف	نماد	VMD-LSTM			GA-LSTM		
		MAE	RMSE	R2	MAE	RMSE	R2
1	یونایتد هلث (UNH)	5,292	6,445	%98,15	3,770	5,093	%98,84
2	گلدمن ساکس (GS)	3,540	4,409	%97,98	2,967	3,996	%98,34
3	آی بی ام (IBM)	2,073	2,738	%95,80	1,746	2,456	%96,62
4	جی پی مورگان (JPM)	1,705	2,097	%98,81	1,44	1,887	%99,03
5	جانسون اند جانسون (JNJ)	1,284	1,733	%96,42	1,295	1,886	%96,09

جدول 7. مقایسه نتایج مدل های پیشنهادی با سایر مدل ها

ردیف	مدل	یونایتد هلث (UNH)			گلدمن ساکس (GS)			جی پی مورگان (JPM)		
		MAE	RMSE	R2	MAE	RMSE	R2	MAE	RMSE	R2
1	VMD-LSTM	5,292	6,445	%98,15	3,540	4,409	%97,98	1,705	2,097	%98,81
2	GA-LSTM	3,770	5,093	%98,84	2,967	3,996	%98,34	1,44	1,887	%99,03
3	EMD-LSTM	5,509	7,567	%97,45	5,433	6,688	%95,37	3,600	4,392	%94,78
4	WT-LSTM	10,785	12,990	%92,53	4,174	5,389	%96,94	2,158	2,827	%97,83
5	LSTM	7,508	9,559	%95,91	3,615	4,738	%97,67	2,718	3,396	%96,87



تصویر 1- نتایج پیشبینی سهام unh با دو مدل پیشنهادی

6. منابع (References)

1. Berradi, Z., Lazaar, M., Mahboub, O. and Omara, H., 2021, June. A comprehensive review of artificial intelligence Techniques in Financial Market. In *2020 6th IEEE congress on information science and technology (CiSt)* (pp. 367-371). IEEE.
<https://doi.org/10.1109/CiSt49399.2021.9357175>
2. Le, D.Y.N., Maag, A. and Senthilanthan, S., 2020, November. Analysing Stock Market Trend Prediction using Machine & Deep Learning Models: A Comprehensive Review. In *2020 5th International Conference on Innovative Technologies in Intelligent Systems and Industrial Applications (CITISIA)* (pp. 1-10). IEEE.
<https://doi.org/10.1109/CITISIA50690.2020.9371852>
3. Arel, I., Rose, D.C. and Karnowski, T.P., 2010. Deep machine learning-a new frontier in artificial intelligence research [research frontier]. *IEEE computational intelligence magazine*, 5(4), pp.13-18.
<https://doi.org/10.1109/MCI.2010.938364>

5. نتیجه گیری و بحث

در این پژوهش دو مدل با دو رویکرد متفاوت انتخاب ویژگی و تجزیه سری زمانی ارائه شد. نتایج نشان داد هر دو مدل پیشنهادی عملکرد مناسب و قابل اتکایی را ارائه می کنند اما مدل VMD-LSTM نسبت به سایر مدل های مشابه مانند الگوریتم تجزیه حالت تجربی و الگوریتم تبدیل موجک عملکرد دقیق تری را ارائه کرده و همچنین در مقایسه دو رویکرد تجزیه سری زمانی قیمت و انتخاب ویژگی، با توجه به نتایج به دست آمده می توان گفت که عملکرد مدل GA-LSTM با رویکرد انتخاب ویژگی دقیق تر بوده و می توان استنباط کرد که به طور کلی مدل های مبتنی بر رویکرد انتخاب ویژگی که پیشبینی را با استفاده از ویژگی های متنوع انجام می دهند، عملکرد مناسب تری نسبت به مدل های مبتنی بر تجزیه سری زمانی ارائه می کنند که تنها از ویژگی قیمتی جهت پیشبینی بهره می برند. همچنین نتایج تحقیق حاضر، حاکی از این است که مدل پیشنهادی که در آن از الگوریتم ژنتیک جهت انتخاب ویژگی استفاده شده است نسبت به مدل پایه که از تمام ویژگی ها در پیشبینی قیمت سهام بهره برده، علاوه بر کاهش ابعاد و محاسبات مدل در نتیجه ی کاهش ویژگی های مورد استفاده در مدل، دقت پیشبینی را نیز به شکل چشمگیری افزایش داده است و می توان استنباط کرد که استفاده از الگوریتم های فراابتکاری در کنار مدل های یادگیری عمیق می تواند عملکرد این مدل ها را در پیشبینی قیمت سهام، بهبود بخشد.

- (DSAA) (pp. 816-825). Ieee.
<https://doi.org/10.1109/DSAA.2016.92>
10. Ding, G. and Qin, L., 2020. Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*, 11(6), pp.1307-1317.
<https://doi.org/10.1007/s13042-019-01041-1>
 11. Liu, Y., 2019. Novel volatility forecasting using deep learning—long short term memory recurrent neural networks. *Expert Systems with Applications*, 132, pp.99-109.
<https://doi.org/10.1016/j.eswa.2019.04.038>
 12. Zeng, X., Cai, J., Liang, C. and Yuan, C., 2022. A hybrid model integrating long short-term memory with adaptive genetic algorithm based on individual ranking for stock index prediction. *Plos one*, 17(8), p.e0272637.
<https://doi.org/10.1371/journal.pone.0272637>
 13. Alotaibi, S.S., 2021. Ensemble technique with optimal feature selection for Saudi stock market prediction: a novel hybrid red deer-grey algorithm. *IEEE Access*, 9, pp.64929-64944.
<https://doi.org/10.1109/ACCESS.2021.3073507>
 14. Chung, H. and Shin, K.S., 2018. Genetic algorithm-optimized long short-term memory network for stock market prediction. *Sustainability*, 10(10), p.3765.
<https://doi.org/10.3390/su10103765>
 4. Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S. and Lew, M.S., 2016. Deep learning for visual understanding: A review. *Neurocomputing*, 187, pp.27-48.
<https://doi.org/10.1016/j.neucom.2015.09.116>
 5. LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *nature*, 521(7553), pp.436-444.
<https://doi.org/10.1038/nature14539>
 6. Adhikari, R. and Agrawal, R.K., 2014. A combination of artificial neural network and random walk models for financial time series forecasting. *Neural Computing and Applications*, 24, pp.1441-1449.
<https://doi.org/10.1007/s00521-013-1386-y>
 7. Niu, H. and Wang, J., 2014. Financial time series prediction by a random data-time effective RBF neural network. *Soft computing*, 18, pp.497-508.
<https://doi.org/10.1007/s00500-013-1070-2>
 8. Das, S.P., Achary, N.S. and Padhy, S., 2016. Novel hybrid SVM-TLBO forecasting model incorporating dimensionality reduction techniques. *Applied Intelligence*, 45, pp.1148-1165.
<https://doi.org/10.1007/s10489-016-0801-3>
 9. Guo, T., Xu, Z., Yao, X., Chen, H., Aberer, K. and Funaya, K., 2016, October. Robust online time series prediction with recurrent neural networks. In *2016 IEEE international conference on data science and advanced analytics*

20. Nasiri, H. and Ebadzadeh, M.M., 2023. Multi-step-ahead stock price prediction using recurrent fuzzy neural network and variational mode decomposition. *Applied Soft Computing*, 148, p.110867. <https://doi.org/10.1016/j.asoc.2023.110867>
21. Mandic, D.P. and Chambers, J.A., 1999. Exploiting inherent relationships in RNN architectures. *Neural networks*, 12(10), pp.1341-1345. [https://doi.org/10.1016/S0893-6080\(99\)00076-3](https://doi.org/10.1016/S0893-6080(99)00076-3)
22. Wang, D., Fan, J., Fu, H. and Zhang, B., 2018. Research on Optimization of Big Data Construction Engineering Quality Management Based on RNN-LSTM. *Complexity*, 2018(1), p.9691868. <https://doi.org/10.1155/2018/9691868>
23. Katoch, S., Chauhan, S.S. and Kumar, V., 2021. A review on genetic algorithm: past, present, and future. *Multimedia tools and applications*, 80, pp.8091-8126. <https://doi.org/10.1007/s11042-020-10139-6>
24. Dragomiretskiy, K. and Zosso, D., 2013. Variational mode decomposition. *IEEE transactions on signal processing*, 62(3), pp.531-544. <https://doi.org/10.1109/TSP.2013.2288675>
15. Niu, H., Xu, K. and Wang, W., 2020. A hybrid stock price index forecasting model based on variational mode decomposition and LSTM network. *Applied Intelligence*, 50, pp.4296-4309. <https://doi.org/10.1007/s10489-020-01814-0>
16. Qiu, J., Wang, B. and Zhou, C., 2020. Forecasting stock prices with long-short term memory neural network based on attention mechanism. *PloS one*, 15(1), p.e0227222. <https://doi.org/10.1371/journal.pone.0227222>
17. Ali, M., Khan, D.M., Alshanbari, H.M. and El-Bagoury, A.A.A.H., 2023. Prediction of complex stock market data using an improved hybrid emd-lstm model. *Applied Sciences*, 13(3), p.1429. <https://doi.org/10.3390/app13031429>
18. Chen, X., Cao, L., Cao, Z. and Zhang, H., 2024. A multi-feature stock price prediction model based on multi-feature calculation, LASSO feature selection, and Ca-LSTM network. *Connection Science*, 36(1), p.2286188. <https://doi.org/10.1080/09540091.2023.2286188>
19. Gülmez, B., 2023. Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. *Expert Systems with Applications*, 227, p.120346. <https://doi.org/10.1016/j.eswa.2023.120346>