

پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی

۱-میرسجاد مسجد موسوی ۲- سپیده خلفی ۳-زهره اشرفی

۱- استادیار، دانشکده مالی و حسابداری، موسسه آموزش عالی الکترونیکی ایرانیان، تهران، ایران.مسئول

۲- استادیار دانشکده مالی و حسابداری، موسسه آموزش عالی الکترونیکی ایرانیان، تهران، ایران

۳- دانشجوی کارشناسی ارشد رشته مدیریت مالی، دانشکده مالی حسابداری، موسسه آموزش عالی الکترونیکی ایرانیان، تهران، ایران

چکیده

سرمایه‌گذاری در سهام بورس اوراق بهادار به عنوان یکی از گزینه‌های سودآور در بازار سرمایه، نیازمند درک عمیق از پویایی‌های پیچیده و غیرخطی این بازار است که تحت تأثیر عوامل سیاسی، اقتصادی و روانشناسی قرار دارد. به منظور دستیابی به سرمایه‌گذاری سودآور و کاهش ریسک، پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار از اهمیت بالایی برخوردار است. در این راستا، استفاده از روش‌های مختلف، به ویژه روش‌های آماری و هوشمند، به کمک سرمایه‌گذاران آمده است. اکثر روش‌های مبتنی بر تجزیه، یک تابع واحد را تقریب می‌کنند که برای دستیابی به نتایج دقیق کافی نیست. علاوه بر این، بیشتر تحقیقات موجود بر پیش‌بینی یک‌مرحله‌ای متمرکز شده‌اند که از سرمایه‌گذاران بازار سهام در رسیدن به بهترین تصمیمات برای آینده جلوگیری می‌کند. استفاده از سیستم‌های هوشمند غیرخطی، مانند شبکه‌های عصبی فازی، می‌تواند به بهبود دقت پیش‌بینی قیمت سهام کمک کند. این مطالعه روشی برای پیش‌بینی چندمرحله‌ای قیمت سهام را بر اساس تکنیک‌های تجزیه مختلف، از جمله تبدیل کسینوسی گسسته (DCT)، که یک تبدیل خطی است، و تجزیه حالت تغییری (VMD)، که یک تبدیل غیرخطی است، پیشنهاد می‌کند. روشی مبتنی بر DCT و شبکه عصبی فازی بازگشتی چندکارکردی (MFRFNN)، است که از DCT برای کاهش نوسانات در سری زمانی و ساده‌سازی ساختار آن و از MFRFNN برای پیش‌بینی قیمت سهام استفاده می‌کند. نتایج نشان می‌دهد VMD-MFRFNN از سایر روش‌های پیشرفته بهتر عمل می‌کند. بر اساس RMSE، برای سری زمانی SSE، VMD-MFRFNN کاهش ۴۳.۵۸٪، را در پیش‌بینی نشان می‌دهد. همچنین، DCT-MFRFNN در همه آزمایش‌ها از MFRFNN بهتر عمل می‌کند، که نشان‌دهنده تأثیر مطلوب DCT بر عملکرد MFRFNN است. روش پیشنهادی نسبت به روش‌های قبلی، پیش‌بینی‌های دقیق‌تری ارائه می‌دهد و از سرعت بالاتری برخوردار است. این یافته‌ها می‌تواند به سرمایه‌گذاران در اتخاذ تصمیمات بهتر و کاهش ریسک‌های مرتبط با سرمایه‌گذاری در بازار سهام کمک نماید.

کلمات کلیدی: پیش‌بینی قیمت سهام، بورس اوراق بهادار، شبکه عصبی فازی.

۱. مقدمه

جهانی سازی اقتصادی، به عنوان یکی از سه بعد اصلی جهانی سازی، باعث نوسانات شدید، چندشکلی و پیچیدگی بالای بازار سهام می شود. پیش بینی قیمت سهام برای سرمایه گذاران و تحلیلگران مالی، به منظور ساخت استراتژی های سرمایه گذاری و کسب بازدهی پایدار، حیاتی است [۱، ۲]. از این رو، مطالعات گسترده ای [۳-۵] در زمینه بهبود رویکردهای پیش بینی سری های زمانی مالی به عنوان یک موضوع تحقیقاتی فعال انجام شده است. یک سری زمانی قیمت سهام، مجموعه ای از مشاهدات متوالی است که در طول زمان از بازار سهام جمع آوری می شود. پیش بینی این سری های زمانی می تواند به صورت یک مرحله ای یا چند مرحله ای انجام شود. بدیهی است که پیش بینی بلندمدت (یعنی چند مرحله ای) برای سرمایه گذاران بازار سهام مفیدتر است تا به بهترین تصمیمات و برنامه های آینده برسند. با این وجود، اکثر تحقیقات موجود در زمینه پیش بینی قیمت سهام [۶-۹] تنها به پیش بینی یک مرحله ای می پردازند. بنابراین، نیاز به بررسی پیش بینی چند مرحله ای قیمت سهام وجود دارد [۲].

مسئله دیگری که نیاز به توجه دارد این است که سری های زمانی مالی معمولاً پویا، غیرخطی، بسیار نوسان دار و پیچیده هستند، که پیش بینی آنها را چالش برانگیز می کند [۹-۱۱]. برای حل این مشکل، روش های مبتنی بر تجزیه پیشنهاد شده اند. ایده اصلی پشت روش های مبتنی بر تجزیه، تجزیه سری های زمانی پیچیده به تعدادی مؤلفه با ساختار ساده تر، یعنی کاهش پیچیدگی سری های زمانی است. از آنجایی که این مؤلفه ها دارای ساختارهای ساده تر و روندهای ثابت تری هستند، پیش بینی آنها آسان تر است و دقت پیش بینی بالاتر خواهد بود [۱۲].

تجزیه حالت تجربی^۷ (EMD)، یک روش تجزیه تطبیقی و مبتنی بر داده، در سال ۱۹۹۸ توسط هوانگ و همکاران [۱۳] پیشنهاد شد. EMD یک سری زمانی را به چندین تابع حالت ذاتی^۸ (IMF) و یک سیگنال باقیمانده تکنوا در یک فرآیند تکراری تجزیه می کند [۱۴]. بنابراین، می تواند به سادگی داده های با نوسان بالا را به مؤلفه های با فرکانس پایین تر تفکیک کند [۹]. اگرچه بسیاری از پژوهشگران از EMD برای پیش بینی سری های زمانی مالی استفاده کرده اند، اما دارای مشکلات ذاتی بسیاری مانند ترکیب حالت ها، عدم وجود مبانی ریاضی، حساسیت به نویز و نمونه برداری، و انتخاب روش درون یابی است [۷، ۱۵]. برای رفع این نواقص، تجزیه حالت تغییر^۹ (VMD) [۱۵]، توسط دراگومیرتسکی و زوسو در سال ۲۰۱۴ پیشنهاد شد. VMD یک روش تجزیه کاملاً غیربازگشتی است که بر اساس یک چارچوب ریاضی قوی استوار است. با حل یک مسئله بهینه سازی محدب، یک سری زمانی را به چندین مؤلفه حالت ویژه با پهنای باند خاص در حوزه طیفی تجزیه می کند. این مؤلفه های محدود به باند، سری زمانی ورودی را دقیقاً یا به کمترین مفهوم مربعات بازسازی می کنند. به عبارت دیگر، VMD قادر به تفکیک تئوهای با فرکانس های مشابه و جلوگیری از مشکل ترکیب حالت ها است [۱، ۱۰، ۱۵].

اگرچه در سال های اخیر، بسیاری از پژوهشگران روش های مبتنی بر تجزیه را با استفاده از VMD به جای EMD توسعه داده اند، تا جایی که به دانش نویسندگان می رسد، همه آنها یک تابع واحد را تقریب می کنند، یعنی یک خروجی خاص را تعیین می کنند که توسط ورودی های فعلی و قبلی تعیین می شود. همانطور که در [۱۶] توضیح داده شده است، در مسائل غیرخطی چالش برانگیز، ممکن است خروجی های مختلفی برای یک ورودی خاص بسته به حالت سیستم تولید شود. بنابراین، برای دستیابی به نتایج دقیق در پیش بینی سری های زمانی مالی، روشی لازم است که بتواند حالت های سیستم را شناسایی کند و یک تابع خاص را برای هر یک از آنها تقریب کند، یعنی باید بتواند همزمان چندین تابع را بیاموزد. شبکه عصبی فازی بازگشتی چندکارکردی^{۱۰} (MFRENN) که توسط نصیری و ابدزاده در سال ۲۰۲۲ پیشنهاد شده است، می تواند همزمان چندین تابع را بیاموزد [۱۶]. با توجه به مسائل مطرح شده، در این مطالعه روشی مبتنی بر شبکه عصبی فازی^{۱۱} به منظور پیش بینی قیمت سهام در بازار بورس اوراق بهادار پیشنهاد شده است.

۲. مرور ادبیات

^۷ Empirical mode decomposition

^۸ intrinsic mode functions

^۹ variational mode decomposition

^{۱۰} Multi-functional recurrent fuzzy neural network

^{۱۱} Fuzzy neural network

این بخش مروری بر ادبیات مرتبط با این مطالعه ارائه می‌دهد. پیش‌بینی قیمت‌های آینده سهام بشدت تحت تأثیر عوامل داخلی و خارجی است. محققان مقالات متعددی برای پیش‌بینی داده‌های سهام منتشر کرده‌اند. پیش‌بینی سری‌های زمانی مالی به عنوان یک مسئله حیاتی برای سرمایه‌گذاران و تحلیلگران مالی، در سال‌های اخیر به طور گسترده مورد مطالعه قرار گرفته است [۱۶-۲۰، ۱۲، ۷-۱۰، ۲، ۱]. چندین پژوهشگر روش‌های مبتنی بر تجزیه را با استفاده از EMD برای پیش‌بینی سری‌های زمانی توسعه داده‌اند. ژو و همکاران [۱۷] EMD^۲FNN را پیشنهاد کردند، یک روش ترکیبی متشکل از EMD و شبکه‌های عصبی مبتنی بر ماشین فاکتورسازی^{۱۲} (FMNN) برای پیش‌بینی روند بازار سهام. EMD^۲FNN مزایای EMD و FMNN را با هم ترکیب می‌کند. یانگ و همکاران [۱۸] یک روش ترکیبی برای پیش‌بینی سری‌های زمانی بر اساس EMD بازگشتی و حافظه کوتاه‌مدت بلند^{۱۳} (LSTM) توسعه دادند. آن‌ها یک EMD بازگشتی جدید برای حل مشکل ترکیب حالت‌های EMD پیشنهاد کردند و از LSTM برای پیش‌بینی IMFها استفاده کردند. کار اخیر دنگ و همکاران [۲] یک چارچوب مدل‌سازی ترکیبی مبتنی بر EMD چندمتغیره (MEMD) و LSTM برای پیش‌بینی شاخص قیمت سهام معرفی کرد. در این چارچوب، ابتدا از MEMD برای تجزیه ویژگی‌های مرتبط سری زمانی استفاده شد. سپس، ویژگی‌های استخراج شده برای آموزش LSTM برای کار پیش‌بینی چندمرحله‌ای استفاده شدند. علاوه بر این، رویکرد تنظیم آرایه متعامد برای تنظیم ابرپارامترهای LSTM به کار گرفته شد. دنگ و همکاران روش پیشنهادی خود را بر روی سه سری زمانی مالی واقعی ارزیابی کردند و نتایج امیدوارکننده‌ای به دست آوردند.

اگرچه بسیاری از پژوهشگران از EMD برای پیش‌بینی سری‌های زمانی استفاده کرده‌اند، اما دارای مشکلات ذاتی بسیاری مانند ترکیب حالت‌ها، اثرات حاشیه‌ای، عدم وجود مبانی ریاضی و حساسیت به نویز است [۲۱]. برای غلبه بر این مسائل، تجزیه حالت تجربی گروهی^{۱۴} (EEMD) توسط وو و هوانگ در سال ۲۰۰۹ پیشنهاد شد [۲۲]. EEMD یک روش تجزیه خودسازگار است که با افزودن نویز سفید، مشکل ترکیب حالت‌های EMD را از بین می‌برد [۱۹، ۱۲]. رضایی و همکاران [۹] CEEMD-CNN-LSTM را توسعه دادند، یک روش ترکیبی با استفاده از EEMD کامل (CEEMD)، شبکه عصبی کانولوشنال^{۱۵} و LSTM روش پیشنهادی آن‌ها می‌تواند ویژگی‌های عمیق و توالی‌های زمانی را استخراج کند. اگرچه CEEMD-CNN-LSTM نتایج امیدوارکننده‌ای در پیش‌بینی یک‌مرحله‌ای قیمت سهام به دست آورد، اما در کارهای پیش‌بینی چندمرحله‌ای ارزیابی نشده است. در سال ۲۰۲۱، لین و همکاران [۸] یک رویکرد ترکیبی را با ترکیب CEEMD با نویز تطبیقی (CEEMDAN) و LSTM پیشنهاد کردند. آن‌ها روش پیشنهادی خود را بر روی سری‌های زمانی شاخص S&P و شاخص سهام ۳۰۰ چین ارزیابی کردند. با وجود غلبه بر مشکلات مرتبط با EMD، EEMD از ناقص بودن، خطای بازسازی، پیچیدگی محاسباتی بالا و مشکل انتخاب پارامترها رنج می‌برد [۲۳، ۸].

VMD، یک روش تجزیه تطبیقی کاملاً غیربازگشتی، توسط Dragomiretskiy و Zosso در سال ۲۰۱۴ برای رفع نواقص EMD پیشنهاد شد. به دلیل مزایای آن، در سال‌های اخیر محبوبیت فزاینده‌ای پیدا کرده است و تلاش‌های متعددی برای توسعه روش‌های مبتنی بر تجزیه با استفاده از VMD انجام شده است. Lahmiri [۲۴] یک مدل پیش‌بینی جدید را با ادغام VMD و شبکه عصبی رگرسیون عمومی معرفی کرد. در [۲۵] یک تکنیک ترکیبی مبتنی بر VMD و LSTM، توسط Niu و همکاران توسعه یافت. در مقاله دیگری، Tang و همکاران [۱۹] یک رویکرد ترکیبی جدید را با ترکیب VMD، EEMD و ماشین یادگیری شدید^{۱۶} (ELM) پیشنهاد کردند. روش پیشنهادی آن‌ها ابتدا VMD را روی سری زمانی اعمال می‌کند و سپس EEMD را روی سیگنال باقیمانده حاصل از VMD اعمال می‌کند. آن‌ها از ELM برای پیش‌بینی شاخص قیمت سهام و تکامل دیفرانسیل برای بهینه‌سازی وزن‌های آن استفاده کردند. مانند [۲۵]، Yujun و همکاران [۱۰] یک مدل پیش‌بینی مبتنی بر VMD و LSTM برای پیش‌بینی قیمت سهام توسعه دادند. در مقاله اخیر Wang و همکاران [۲۶] یک روش ترکیبی جدید مبتنی بر تجزیه ثانویه^{۱۷} (SD)، تحلیل چندعاملی و LSTM مبتنی بر توجه پیشنهاد کردند. در این روش، SD از VMD

^{۱۲} factorization machine-based neural networks

^{۱۳} long short-term memory

^{۱۴} ensemble empirical mode decomposition

^{۱۵} Convolutional neural network


^{۱۶} extreme learning machine

^{۱۷} secondary decomposition

بهبود یافته و CEEMDAN بهبود یافته برای فیلتر کردن مؤثر نویز و گرفتن ویژگی‌های غیرخطی اضافی استفاده می‌کند. لایه توجه به LSTM اضافه شد تا وزن نمونه‌های داده مهم افزایش یابد و عملکرد LSTM بهبود یابد. روش VML توسط Liu و همکاران [۱] در سال ۲۰۲۲ توسعه یافت. VML یادگیری فرامتا و VMD را ادغام می‌کند. از VMD برای تجزیه سری‌های زمانی و از یادگیری فرامتا مستقل از مدل و LSTM برای پیش‌بینی هر مؤلفه استفاده می‌کند. Liu و همکاران از شاخص بورس شانگهای و میانگین صنعتی داوجونز برای ارزیابی VML استفاده کردند. Guo و همکاران [۷] یک روش ترکیبی مبتنی بر VMD، میانگین متحرک خودرگرسیون تلفیقی^{۱۸} (ARIMA) و پیش‌بینی گسترش تیلور^{۱۹} (TEF) معرفی کردند. آن‌ها از VMD برای تجزیه سری‌های زمانی، ARIMA برای پیش‌بینی مؤلفه خطی هر IMF و TEF برای پیش‌بینی مؤلفه غیرخطی استفاده کردند.

۳. روش

MFRFNN، که توسط نصیری و ابدزاده در سال ۲۰۲۲ پیشنهاد شد، یک شبکه عصبی فازی بازگشتی برای پیش‌بینی سری‌های زمانی است. این شبکه شامل دو شبکه عصبی فازی (FNN) است. یکی از آن‌ها، یعنی شبکه خروجی، خروجی سیستم را تولید می‌کند، در حالی که دیگری، یعنی شبکه حالت، حالت سیستم را شناسایی می‌کند (شکل ۱). MFRFNN از الگوریتم کمترین مربعات و تکنیک بهینه‌سازی ازدحام ذرات^{۲۰} (PSO) برای یادگیری وزن‌های شبکه‌های خروجی و حالت به ترتیب استفاده می‌کند. این شبکه می‌تواند داده‌های تاریخی را از نمونه‌های سری زمانی قبلی بیاموزد و حفظ کند و با ادغام حالت‌ها در ساختار خود، چندین تابع را همزمان تقریب کند [۷].




شکل ۱: معماری MFRFNN [۱۶].

روش پیشنهادی DCT-MFRFNN از مراحل زیر تشکیل شده است:

۱. تبدیل کسینوسی گسسته (DCT) به سری زمانی ورودی اعمال می‌شود و ضرایب (c) DCT محاسبه می‌شوند.
۲. λ درصد از ضرایب DCT با فرکانس بالا به صفر تنظیم می‌شوند.
۳. DCT معکوس به ضرایب باقیمانده اعمال می‌شود و سیگنال ورودی بازسازی می‌شود.
۴. سیگنال بازسازی شده ($\hat{x}$) به عنوان ورودی برای آموزش به MFRFNN داده می‌شود.
۵. MFRFNN پیش‌بینی نهایی ($\hat{y}$) را تولید می‌کند.

شکل ۲ ساختار DCT-MFRFNN را نشان می‌دهد.



شکل ۲: ساختار DCT-MFRFNN

^{۱۸} autoregressive integrated moving average

^{۱۹} Taylor expansion forecasting

^{۲۰} particle swarm optimization


در DCT-MFRFNN، یک دنباله از ضرایب DCT با فرکانس بالا حذف می‌شود تا فرکانس‌های بالا حذف شود و نوسانات در سری زمانی کاهش یابد. در نتیجه، یک سری زمانی با ساختار ساده‌تر و روندهای ثابت‌تر به MFRFNN برای پیش‌بینی داده می‌شود. به طور شهودی، از آنجایی که این سری زمانی دارای ساختار ساده‌تری است، پیش‌بینی آن برای مدل آسان‌تر است. روش آموزش DCT-MFRFNN در الگوریتم ۱ نشان داده شده است.

Algorithm ۱: DCT-MFRFNN training algorithm Input: Input time series $D = \{x^{[t]}, x^{[t+h]}\} \quad t=1^p, \lambda$ Output: Predicted signal ($\hat{y}$) Apply DCT to x to obtain $c \in R^{p \times ۱}$ $n \leftarrow \lfloor p \times (۱۰۰ - \lambda) / ۱۰۰ \rfloor + ۱$ for $i \leftarrow n$ to p do $C_i \leftarrow \cdot$ end Apply IDCT to c to obtain $\hat{x}$ Train MFRFNN using $\hat{x}$ as input Predict $\hat{y}$ using MFRFNN model

VMD-MFRFNN از دو فاز تشکیل شده است: الف) فاز تجزیه و ب) فاز پیش‌بینی و بازسازی. در فاز تجزیه، سری زمانی ورودی با استفاده از روش VMD به چندین IMF تجزیه می‌شود. در فاز پیش‌بینی و بازسازی، ابتدا هر یک از IMFها به یک مدل MFRFNN جداگانه برای آموزش داده می‌شود. سپس، هر مدل سیگنال پیش‌بینی شده خود را تولید می‌کند، یعنی خروجی هر MFRFNN در نهایت، سیگنال‌های پیش‌بینی شده برای بازسازی پیش‌بینی نهایی جمع می‌شوند. شکل ۳ ساختار VMD-MFRFNN را نشان می‌دهد. توضیح کامل در مورد فازهای VMD-MFRFNN در زیر ارائه شده است.

فاز تجزیه: در این فاز، سیگنال ورودی با استفاده از VMD به K IMF تجزیه می‌شود. فرض کنید $D = \{x^{[t]}, x^{[t+h]}, \dots, x^{[t+p-1]}\}$ سری زمانی ورودی باشد، که در آن h و p به ترتیب نشان دهنده افق پیش‌بینی و تعداد نمونه‌ها هستند.

فاز پیش‌بینی و بازسازی: هر یک از صندوق‌های بین‌المللی پول در این مرحله به یک MFRFNN جداگانه به عنوان ورودی برای آموزش مدل‌ها داده می‌شود.



شکل ۳: معماری VMD-MFRFNN

VMD-MFRFNN از دو فاز تشکیل شده است: الف) فاز تجزیه و ب) فاز پیش‌بینی و بازسازی. در فاز تجزیه، سری زمانی ورودی با استفاده از روش VMD به K IMF تجزیه می‌شود. در فاز پیش‌بینی و بازسازی، ابتدا هر یک از IMFها به یک MFRFNN جداگانه به عنوان ورودی برای آموزش مدل‌ها داده می‌شود. سپس، هر مدل سیگنال پیش‌بینی شده خود را تولید می‌کند، یعنی خروجی هر MFRFNN در نهایت، سیگنال‌های پیش‌بینی شده برای بازسازی پیش‌بینی نهایی جمع می‌شوند. توضیحات فازهای VMD-MFRFNN در زیر ارائه شده است.

فاز تجزیه: در این فاز، سیگنال ورودی با استفاده از VMD به K IMF تجزیه می‌شود. فرض کنید $D = \{x[t], x[t+h], \dots, x[t+p-1]\}$ سری زمانی ورودی باشد، که در آن h و p به ترتیب نشان دهنده افق پیش‌بینی و تعداد نمونه‌ها هستند. VMD با گرفتن K به عنوان ورودی، x را به K IMF تجزیه می‌کند. بدیهی است که این مؤلفه‌ها دارای ساختارهای ساده‌تری هستند، بنابراین فاز تجزیه به روش پیشنهادی اجازه می‌دهد تا ساختارهای ساده‌تر با روندهای ثابت‌تر را پیش‌بینی کند و به دقت بالاتر دست یابد.

فاز پیش‌بینی و بازسازی: در این فاز، هر یک از IMFها به یک MFRFNN جداگانه به عنوان ورودی برای آموزش مدل‌ها داده می‌شود. روش آموزش VMD-MFRFNN در الگوریتم ۲ نشان داده شده است. با فرض اینکه تعداد قواعد فازی شبکه‌های خروجی و حالت در همه MFRFNNها برابر است، تعداد پارامترهای قابل آموزش VMD-MFRFNN برابر با $(K^1 + K^2) \times N \times K$ است، که در آن K^1 و K^2 به ترتیب تعداد قواعد فازی شبکه‌های خروجی و حالت را نشان می‌دهند و N تعداد حالت‌های هر MFRFNN است.

Algorithm ۲: VMD-MFRFNN training algorithm
Input: Input time series $D = \{x^{[t]}, x^{[t+h]}\}_{t=1}^p, K$ Output: Predicted signal ($\hat{y}$) Decompose x to obtain $\{imf_i\}_{i=1}^K$ for $i \leftarrow 1$ to K do Train MFRFNN _{i} using imf_i as input Predict $\hat{y}_i$ using MFRFNN _{i} model end $\hat{y} \leftarrow \sum_{i=1}^K [\hat{y}_i^1, \hat{y}_i^2, \dots, \hat{y}_i^p]$

۴. نتایج

عملکرد پیش‌بینی DCT-MFRFNN و VMD-MFRFNN بر روی سه سری زمانی مالی، از جمله شاخص هنگ سنگ (HSI)، بورس شانگهای (SSE) و شاخص استاندارد و پور ۵۰۰ (SPX) ارزیابی شده است. همه سری‌های زمانی از Yahoo Finance جمع‌آوری شده‌اند. جدول ۱: توصیف آماری این سری‌های زمانی را خلاصه می‌کند.

جدول ۱: توصیف آماری سری‌های زمانی مالی

سری زمانی	تعداد نمونه‌ها	حداقل	حداکثر	میانگین	انحراف استاندارد
HIS	۲۲۶۱	۱۶۲۵۰.۲۷	۳۳۱۵۴.۱۲	۲۳۴۱۸.۲۳	۳۰۹۷.۴۴
SSE	۲۲۱۸	۱۹۵۰.۰۱	۵۱۶۶.۳۵	۲۷۹۸.۸۸	۵۵۰.۷۰
SPX	۲۷۶۹	۱۰۲۲.۵۸	۳۷۵۶.۰۷	۲۰۷۷.۳۰	۶۷۴.۷۲


روش VMD در همه سری‌های زمانی مالی عملکرد بهتری نسبت به سایر روش‌ها داشته است، و پس از آن EEMD قرار دارد. بنابراین، استفاده از VMD به عنوان روش تجزیه در ساختار روش پیشنهادی، انتخاب خوبی است. پارامترهای روش‌های پیشنهادی با استفاده از مجموعه اعتبارسنجی در هر سری زمانی از طریق آزمون و خطا انتخاب شدند. جدول ۲ پارامترهای انتخاب شده برای هر سری زمانی را فهرست می‌کند. همانطور که ذکر شد، VMD IMF ها را به ترتیب از فرکانس‌های بالاتر به پایین‌تر استخراج می‌کند. بنابراین، به طور شهودی، تعداد قواعد فازی شبکه خروجی برای چندین MFRFNN باید بیشتر از چندین MFRFNN آخر باشد. از توابع عضویت مثلثی برای لایه ورودی روش‌های پیشنهادی استفاده شد. برای الگوریتم PSO، وزن اینرسی به صورت تطبیقی در محدوده [۰.۱، ۱.۱] انتخاب شد و ضرایب شتاب شناختی و اجتماعی در همه آزمایش‌ها روی ۱.۴۹ تنظیم شدند.

جدول ۲: پارامترهای روش‌های پیشنهادی در هر سری زمانی مالی

سری زمانی	تعداد قواعد فازی شبکه خروجی	تعداد قواعد فازی (MFRFNN ^۱ , MFRFNN ^۲ , ..., MFRFNN ^۹)	تعداد قواعد فازی شبکه حالت (شبکه حالت)	تعداد قواعد حالت ها	حداکثر تعداد ارزیابی توابع هدف (PSO)	تعداد IMF ها	λ
HIS	[۴۴۴۵۵۵۶۶۶]	۲	۲	۲	۶۰۰	۹	۸۰
SSE	[۲۲۲۳۳۳۴۴۴]	۴	۴	۲	۸۰۰	۹	۸۵
SPX	[۲۲۲۳۳۳۴۴۴]	۲	۲	۲	۶۰۰	۹	۸۶


شاخص هنگ سنگ (HSI) شاخص بازار سهام در هنگ کنگ است. این شاخص شاخص اصلی عملکرد کل بازار سهام هنگ کنگ است و برای ردیابی تغییرات روزانه در شرکت‌های برتر فهرست‌شده در بورس هنگ کنگ استفاده می‌شود. این شاخص نمونه‌ای از بازارهای نسبتاً توسعه‌یافته با معاملات فعال است [۲]. داده‌های HSI در طول یک دوره نه ساله از ۴ ژانویه ۲۰۱۰ تا ۸ مارس ۲۰۱۹ از وبسایت Yahoo Finance جمع‌آوری شده است. مجموعه‌های آموزشی و آزمایشی در این آزمایش به ترتیب شامل ۱۵۰۹، ۳۷۶ و ۳۷۶ نمونه هستند. شکل ۴ منحنی پیش‌بینی مؤلفه‌های تجزیه VMD برای سری زمانی HSI را که توسط VMD-MFRFNN تولید شده‌اند، نشان می‌دهد. همانطور که مشاهده می‌شود، VMD-MFRFNN مؤلفه‌های IMF با فرکانس پایین را با دقت بالا و مؤلفه‌های IMF با فرکانس بالا را با

دقت پایین پیش‌بینی می‌کند زیرا تعداد قواعد فازی برای مدل‌سازی دقیق مؤلفه‌های IMF با فرکانس بالا خیلی کم است. به طور شهودی، پیش‌بینی مؤلفه‌های IMF با فرکانس بالا یک بایاس برای VMD-MFRFNN است که خروجی نهایی را تنظیم می‌کند.



شکل ۴: منحنی پیش‌بینی اجزای تجزیه VMD برای سری زمانی HSI


شکل ۵: منحنی پیش‌بینی و هیستوگرام خطا برای سری زمانی HSI را که توسط VMD-MFRFNN تولید شده‌اند، نشان می‌دهد. توزیع گاوسی خطاها نشان می‌دهد که VMD-MFRFNN به طور مؤثری خواص دینامیکی سری زمانی را درک کرده است.



شکل ۵: منحنی پیش بینی و هیستوگرام خطا برای سری زمانی HIS


بورس شانگهای (SSE) یک بورس اوراق بهادار مستقر در شانگهای، چین است. بر اساس ارزش بازار، SSE سومین بازار بورس بزرگ در جهان است و نماینده یک بازار در حال توسعه است. داده‌های سری زمانی SSE شامل ۲۲۱۸ نمونه است که از Yahoo Finance در طول یک دوره نه ساله از ۳۱ دسامبر ۲۰۱۰ تا ۲۱ فوریه ۲۰۲۰ به دست آمده است. ۱۴۷۸ نمونه اول برای آموزش، ۳۷۰ نمونه برای اعتبارسنجی و ۳۷۰ نمونه برای تست استفاده شد.

پیش‌بینی سری زمانی SSE، نشان‌دهنده عملکرد بهتر VMD-MFRFNN نسبت به سایر روش‌ها در پیش‌بینی سری زمانی SSE است. براساس RMSE، VMD-MFRFNN در پیش‌بینی بالاترین دقت را داشت. بر اساس این معیار، VMD-MFRFNN کاهش ۴۳.۵۸٪ را در وظایف پیش‌بینی نشان داد. مدل SSE به دلیل توانایی یادگیری همزمان چندین تابع و استفاده از روش تجزیه برای ساده سازی مسئله پیش‌بینی توضیح داده می‌شود. استفاده از دو حالت به VMD-MFRFNN اجازه می‌دهد تا رفتارهای دینامیکی مجموعه داده‌های SSE را در طول زمان یاد بگیرد و ردیابی کند. علاوه بر این، VMD-MFRFNN به عنوان یک FNN، نویز سری زمانی را حذف می‌کند. منحنی پیش‌بینی و هیستوگرام خطای تولید شده توسط VMD-MFRFNN برای سری زمانی SSE در شکل ۶ نشان داده شده است.



شکل ۶: منحنی پیش‌بینی و هیستوگرام خطاها برای سری زمانی SSE

شاخص استاندارد و پور ۵۰۰ (SPX) قیمت سهام ۵۰۰ شرکت سهامی عام داخلی در ایالات متحده را ردیابی می‌کند. SPX معمولاً به عنوان یکی از توسعه‌یافته‌ترین بازارهای جهان به دلیل سیستم عملیاتی بازار بالغ شناخته می‌شود [۲]. داده‌های SPX نیز از وبسایت Yahoo Finance در طول یک دوره یازده ساله از ۴ ژانویه ۲۰۱۰ تا ۳۱ دسامبر ۲۰۲۰ جمع‌آوری شده است. از کل داده‌های سری زمانی، ۱۸۴۵ نمونه به عنوان مجموعه آموزشی، ۴۶۲ نمونه به عنوان مجموعه اعتبارسنجی و ۴۶۲ نمونه باقیمانده به عنوان مجموعه تست در نظر گرفته شده است. با توجه به نتایج VMD-MFRFNN با MFRFNN مشخص شد که VMD-MFRFNN دقت و انحراف استاندارد بالاتری داشته است. داشتن انحراف استاندارد بالا یکی از معایب VMD-MFRFNN پیشنهادی است. با افزایش انحراف استاندارد، واریانس پیش‌بینی‌ها نیز افزایش می‌یابد. شکل ۷ منحنی پیش‌بینی و هیستوگرام خطا تولید شده توسط VMD-MFRFNN را برای مجموعه داده SPX نشان می‌دهد.



شکل ۷: منحنی پیش‌بینی و هیستوگرام خطاها برای سری زمانی SPX

۵. نتیجه‌گیری

روش‌های DCT-MFRFNN و VMD-MFRFNN به عنوان تکنیک‌های پیشرفته برای پیش‌بینی سری‌های زمانی مالی، عملکرد بهتری نسبت به مدل‌های پیشین دارند. DCT-MFRFNN با استفاده از DCT برای حذف فرکانس‌های بالا و کاهش نوسانات، به ساده‌سازی ساختار سری‌های زمانی کمک می‌کند. از سوی دیگر، VMD-MFRFNN با تجزیه سری‌های زمانی به مؤلفه‌های IMF و استفاده از مدل‌های MFRFNN برای پیش‌بینی، دقت پیش‌بینی را افزایش می‌دهد. نتایج تجربی نشان می‌دهد که VMD-MFRFNN در پیش‌بینی‌ها از جمله در سری‌های زمانی HSI، SSE و SPX بهتر از سایر مدل‌ها عمل کرده و کاهش‌های قابل توجهی در RMSE نسبت به مدل‌های قبلی نشان داده است. به‌ویژه، این کاهش‌ها در افق‌های پیش‌بینی مختلف حاکی از قابلیت‌های بالای این روش‌ها در پیش‌بینی دقیق‌تر است. علاوه بر این، DCT-MFRFNN نیز در تمامی آزمایش‌ها از MFRFNN عملکرد بهتری داشته و کاهش‌های قابل توجهی در RMSE نشان داده است. بر اساس RMSE، برای سری زمانی SSE، VMD-MFRFNN کاهش ۴۳.۵۸٪ را در پیش‌بینی نشان می‌دهد. علاوه بر این، DCT-MFRFNN در همه آزمایش‌ها از MFRFNN بهتر عمل کرد. این نتایج نشان‌دهنده پتانسیل بالای روش‌های پیشنهادی در پیش‌بینی سری‌های زمانی مالی است و نیاز به تحقیقات بیشتر در این زمینه را تأکید می‌کند. همچنین، پیشنهاد می‌شود که این روش‌ها در زمینه‌های دیگر مانند هواشناسی و مهندسی پزشکی نیز مورد مطالعه قرار گیرند تا کاربردهای وسیع‌تری از آن‌ها کشف شود.

۶. منابع

- [۱] T. Liu, X. Ma, S. Li, X. Li, C. Zhang, A stock price prediction method based on meta-learning and variational mode decomposition, Knowledge-Based Systems ۲۵۲ (۲۰۲۲) ۱۰۹۳۲۴. doi:۱۰,۱۰۱۶/j.knosys.۲۰۲۲,۱۰۹۳۲۴.
- [۲] C. Deng, Y. Huang, N. Hasan, Y. Bao, Multi-step-ahead stock price index forecasting using long shortterm memory model with multivariate empirical mode decomposition, Information Sciences ۶۰۷ (۲۰۲۲) ۲۹۷-۳۲۱. doi:۱۰,۱۰۱۶/j.ins.۲۰۲۲,۰۵,۰۸۸.
- [۳] S. Anbaee Farimani, M. Vafaei Jahan, A. Milani Fard, S. R. K. Tabbakh, Investigating the informativeness of technical indicators and news sentiment in financial market price prediction, Knowledge-Based Systems ۲۴۷ (۲۰۲۲) ۱۰۸۷۴۲. doi:۱۰,۱۰۱۶/j.knosys.۲۰۲۲,۱۰۸۷۴۲.
- [۴] Y. Huang, Y. Deng, A new crude oil price forecasting model based on variational mode decomposition, Knowledge-Based Systems ۲۱۳ (۲۰۲۱) ۱۰۶۶۶۹. doi:۱۰,۱۰۱۶/j.knosys.۲۰۲۰,۱۰۶۶۶۹.
- [۵] N. Seong, K. Nam, Forecasting price movements of global financial indexes using complex quantitative financial networks, Knowledge-Based Systems ۲۳۵ (۲۰۲۲) ۱۰۷۶۰۸. doi:۱۰,۱۰۱۶/j.knosys.۲۰۲۱, ۱۰۷۶۰۸.
- [۶] J. Cao, J. Wang, Stock price forecasting model based on modified convolution neural network and financial time series analysis, International Journal of Communication Systems ۳۲ (۱۲) (۲۰۱۹) e۳۹۸۷. doi:۱۰,۱۰۰۲/dac.۳۹۸۷.
- [۷] W. Guo, Q. Liu, Z. Luo, Y. Tse, Forecasts for international financial series with VMD algorithms, Journal of Asian Economics ۸۰ (۲۰۲۲) ۱۰۱۴۵۸. doi:۱۰,۱۰۱۶/j.asieco.۲۰۲۲,۱۰۱۴۵۸.
- [۸] Y. Lin, Y. Yan, J. Xu, Y. Liao, F. Ma, Forecasting stock index price using the CEEMDAN-LSTM model, The North American Journal of Economics and Finance ۵۷ (۲۰۲۱) ۱۰۱۴۲۱. doi:۱۰,۱۰۱۶/j.najef.۲۰۲۱,۱۰۱۴۲۱.

- [٩] H. Rezaei, H. Faaljou, G. Mansourfar, Stock price prediction using deep learning and frequency decomposition, *Expert Systems with Applications* ١٦٩ (٢٠٢١) ١١٤٣٣٢. doi:١٠.١٠١٦/j.eswa.٢٠٢٠.١١٤٣٣٢.
- [١٠] Y. Yujun, Y. Yimei, Z. Wang, Research on a hybrid prediction model for stock price based on long short-term memory and variational mode decomposition, *Soft Computing* ٢٥ (٢١) (٢٠٢١) ١٣٥١٣–١٣٥٣١. doi:١٠.١٠٠٧/s٠٠٥٠٠٠٠٠٢١٠٠٦١٢٢-٤.
- [١١] H. Xu, D. Cao, S. Li, A self-regulated generative adversarial network for stock price movement prediction based on the historical price and tweets, *Knowledge-Based Systems* ٢٤٧ (٢٠٢٢) ١٠٨٧١٢. doi:١٠.١٠١٦/j.knosys.٢٠٢٢.١٠٨٧١٢.
- [١٢] H.-P. Nguyen, P. Baraldi, E. Zio, Ensemble empirical mode decomposition and long short-term memory neural network for multi-step predictions of time series signals in nuclear power plants, *Applied Energy* ٢٨٣ (٢٠٢١) ١١٦٣٤٦. doi:١٠.١٠١٦/j.apenergy.٢٠٢٠.١١٦٣٤٦.
- [١٣] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, H. H. Liu, 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* ٤٥٤ (١٩٧١) (١٩٩٨) ٩٠٣–٩٩٥. doi:١٠.١٠٩٨/rspa.١٩٩٨.٠١٩٣.
- [١٤] Z. Liu, J. Liu, A robust time series prediction method based on empirical mode decomposition and highorder fuzzy cognitive maps, *Knowledge-Based Systems* ٢٠٣ (٢٠٢٠) ١٠٦١٠٥. doi:١٠.١٠١٦/j.knosys.٢٠٢٠.١٠٦١٠٥.
- [١٥] K. Dragomiretskiy, D. Zosso, Variational Mode Decomposition, *IEEE Transactions on Signal Processing* ٦٢ (٣) (٢٠١٤) ٥٣١–٥٤٤. doi:١٠.١١٩/TSP.٢٠١٣.٢٢٨٨٦٧٥.
- [١٦] H. Nasiri, M. M. Ebadzadeh, MFRFNN: Multi-Functional Recurrent Fuzzy Neural Network for Chaotic Time Series Prediction, *Neurocomputing* ٥٠٧ (٢٠٢٢) ٢٩٢–٣١٠. doi:١٠.١٠١٦/j.neucom.٢٠٢٢.٠٨.٠٣٢.
- [١٧] F. Zhou, H.-m. Zhou, Z. Yang, L. Yang, EMD٢FNN: A strategy combining empirical mode decomposition and factorization machine based neural network for stock market trend prediction, *Expert Systems with Applications* ١١٥ (٢٠١٩) ١٣٦–١٥١. doi:١٠.١٠١٦/j.eswa.٢٠١٨.٠٧.٠٦٥.
- [١٨] Y. Yang, C. Fan, H. Xiong, A novel general-purpose hybrid model for time series forecasting, *Applied Intelligence* ٥٢ (٢) (٢٠٢٢) ٢٢١٢–٢٢٢٣. doi:١٠.١٠٠٧/s١٠٤٨٩٠٠٢١٠٠٢٤٤٢-y.
- [١٩] Z. Tang, T. Zhang, J. Wu, X. Du, K. Chen, Multistep-Ahead Stock Price Forecasting Based on Secondary Decomposition Technique and Extreme Learning Machine Optimized by the Differential Evolution Algorithm, *Mathematical Problems in Engineering* ٢٠٢٠ (٢٠٢٠) ١–١٣. doi:١٠.١١٥٥/٢٠٢٠/٢٦٠٤٩١٥.
- [٢٠] A. Salimi-Badr, M. M. Ebadzadeh, A novel learning algorithm based on computing the rules' desired outputs of a TSK fuzzy neural network with non-separable fuzzy rules, *Neurocomputing* ٤٧٠ (٢٠٢٢) ١٣٩–١٥٣. doi:١٠.١٠١٦/j.neucom.٢٠٢١.١٠.١٠٣.
- [٢١] Y. Liu, C. Yang, K. Huang, W. Gui, Non-ferrous metals price forecasting based on variational mode decomposition and LSTM network, *Knowledge-Based Systems* ١٨٨ (٢٠٢٠) ١٠٥٠٠٦. doi:١٠.١٠١٦/j.knosys.٢٠١٩.١٠٥٠٠٦.
- [٢٢] Z. Wu, N. E. Huang, Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method, *Advances in Adaptive Data Analysis* ٠١ (٠١) (٢٠٠٩) ١–٤١. doi:١٠.١١٤٢/S١٧٩٣٥٣٦٩٠٩٠٠٠٠٤٧.

[୪୩] S. Y. Rashida, M. Sabaei, M. M. Ebadzadeh, A. M. Rahmani, An intelligent approach for predicting resource usage by combining decomposition techniques with NFTS network, Cluster Computing ୨୩ (୫) (୨୦୨୦) ୩୫୩୦–୩୫୬୦. doi:10.1007/s10686-020-03099-x.

[୪୪] S. Lahmiri, A variational mode decomposition approach for analysis and forecasting of economic and financial time series, Expert Systems with Applications ୧୦ (୨୦୧୬) ୨୬୮–୨୭୩. doi:10.1016/j.eswa.2016.02.020.

[୪୫] H. Niu, K. Xu, W. Wang, A hybrid stock price index forecasting model based on variational mode decomposition and LSTM network, Applied Intelligence ୧୦ (୧୨) (୨୦୨୦) ୫୨୩୬–୫୩୦୩. doi:10.1007/s10489-020-0181୫-୦.

[୪୬] J. Wang, Q. Cui, X. Sun, M. He, Asian stock markets closing index forecast based on secondary decomposition, multi-factor analysis and attention-based LSTM model, Engineering Applications of Artificial Intelligence ୧୧୩ (୨୦୨୨) 10490୮. doi:10.1016/j.engappai.2022.10490୮.