مقاله پژوهشی

روشی ترکیبی جهت پیش‌بینی قیمت سهام در بازار بورس ایران با بهره‌گیری از یادگیری عمیق بهینه‌شده

محسن مهدوی اصل و مارال کلاه‌کج

چکیده: پیش‌بینی دقیق قیمت سهام همواره یکی از چالش‌های اساسی در بازارهای مالی بوده است و توسعه‌ی مدل‌های هوشمند می‌تواند نقش مؤثری در تصمیم‌گیری سرمایه‌گذاران ایفا کند. در این پژوهش، یک چارچوب ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی قیمت سهام در بازار سرمایه ایران ارائه شده است. روش پیشنهادی از شبکه عصبی کانولوشنی به‌عنوان هسته‌ی اصلی یادگیری و از الگوریتم فراابتکاری شاهین هریس برای بهینه‌سازی وزن‌ها و پارامترهای مدل بهره می‌گیرد. هدف از این ترکیب، افزایش دقت پیش‌بینی و کاهش پیچیدگی محاسباتی از طریق یادگیری خودکار ویژگی‌ها در لایه‌های میانی شبکه است. داده‌های مورداستفاده شامل اطلاعات روزانه‌ی سهام شرکت بهمن خودرو از تاریخ ۱۸/۰۱/۱۳۸۰ تا ۲۳/۱۲/۱۳۹۹ بوده و متغیرهایی مانند تعداد تراکنش‌ها، حجم معاملات، ارزش، و قیمت‌های دیروز، اولین، آخرین، پایانی، کمترین و بیشترین را در بر می‌گیرد. نتایج شبیه‌سازی‌ها نشان می‌دهد که مدل پیشنهادی CNN-HHO نسبت به روش‌های متداول مبتنی بر شبکه‌های عصبی و الگوریتم‌های فراابتکاری، عملکرد بهتری داشته و مقدار خطای MSEآن به طور محسوسی کمتر است. به‌طورکلی، نتایج این تحقیق نشان می‌دهد که ترکیب CNN با الگوریتم HHO می‌تواند به‌عنوان یک رویکرد هوشمند، دقیق و کارا برای پیش‌بینی سری‌های زمانی مالی مورداستفاده قرار گیرد و راهکار مؤثری برای تصمیم‌گیری آگاهانه‌تر در بازار بورس فراهم سازد.

کلیدواژه: **بهینه‌سازی، پیش‌بینی، شبکه عصبی کانولوشن، یادگیری عمیق.**

۱- مقدمه

در سال‌های اخیر، رشد فزاینده‌ی داده‌ها و اطلاعات در حوزه‌های مختلف اقتصادی و مالی، نیاز به روش‌ها و تکنیک‌های کارا برای دستیابی، اشتراک‌گذاری و استخراج دانش از داده‌ها را بیش‌ازپیش نمایان ساخته است [۱]. حجم انبوه داده‌های تولیدشده در سازمان‌ها، درحالی‌که چالش‌هایی در زمینه‌ی ذخیره‌سازی، جمع‌آوری و طبقه‌بندی داده‌ها ایجاد می‌کند، درعین‌حال حاوی دانشی ارزشمند است که در صورت تحلیل صحیح، می‌تواند به مزیت رقابتی و تصمیم‌گیری هوشمند منجر شود [۲]. در این میان، سازمان‌های یادگیرنده و هوشمند تلاش می‌کنند با بهره‌گیری از تحلیل داده و کشف الگوهای پنهان، عملکرد خود را بهبود دهند و فرصت‌های جدیدی برای رشد شناسایی نمایند. این روند منجر به ظهور شاخه‌ای نوین از علم تحت عنوان مهندسی مالی[1] شده است [۳] و [۴].

مهندسی مالی با بهره‌گیری از ابزارها و مدل‌های نوآورانه، درصدد کاهش ریسک و افزایش بازدهی در تصمیم‌گیری‌های مالی است. یکی از مهم‌ترین حوزه‌های کاربردی آن، بازار بورس اوراق بهادار است که به‌عنوان رکن اصلی بازارهای مالی، نقشی حیاتی در هدایت سرمایه‌ها، تسهیل سرمایه‌گذاری و توسعه‌ی اقتصادی ایفا می‌کند [۵]. همچنین، بازار بورس به‌عنوان یکی از نهادهای مالی کلیدی، بستری مناسب برای طراحی و پیاده‌سازی ابزارهای نوین مالی و حضور فعال سرمایه‌گذاران فراهم می‌سازد [۶] و [۷].

در میان روش‌های نوین تحلیل بازار بورس، تکنیک‌های داده‌کاوی[2] از جایگاه ویژه‌ای برخوردار شده‌اند [۸]. داده‌کاوی به‌عنوان ابزاری توانمند برای تحلیل رفتار بازار و شناسایی الگوهای پنهان در داده‌های مالی شناخته می‌شود. این روش‌ها با تحلیل داده‌های تاریخی مرتبط با قیمت دارایی‌ها (مانند طلا، فلزات گران‌بها و سهام شرکت‌ها)، قادرند الگوهای رفتاری تکرارشونده را استخراج و بر اساس آن، روندهای آتی را پیش‌بینی نمایند [۹] و [۱۰]. به‌کارگیری چنین روش‌هایی علاوه بر بهبود کارایی سیستم‌های مالی، به افزایش دقت تصمیم‌گیری و در نهایت، ارتقای سودآوری سازمان‌ها منجر می‌شود [۱۱] و [۱۲].

به‌طورکلی، پیش‌بینی[3] به معنای گمانه‌زنی درباره‌ی وضعیت یا رخدادهای آینده بر اساس داده‌های گذشته است [۱۳]. یکی از مهم‌ترین ابزارهای ریاضی در این زمینه، سری‌های زمانی[4] هستند [۱۴]. سری زمانی در واقع دنباله‌ای از مشاهدات است که بر اساس زمان یا متغیری دیگر با فواصل مساوی مرتب می‌شود [۱۵]. تحلیل سری‌های زمانی همواره یکی از ارکان اساسی در مدل‌سازی داده‌های مالی بوده و مبنای بسیاری از روش‌های پیش‌بینی سنتی مانند مدل‌های ساختاری و آماری به شمار می‌رود.

در سال‌های اخیر، در کنار مدل‌های کلاسیک [۱۶]، شبکه‌های عصبی مصنوعی[5] (ANNs) به‌عنوان ابزارهایی توانمند در مدل‌سازی روابط غیرخطی و پیچیده معرفی شده‌اند. این مدل‌ها که الهام‌گرفته از سازوکار یادگیری مغز انسان هستند، قادرند با استفاده از توان محاسباتی بالا، روابط

این مقاله در تاریخ ۲۶ فروردین ماه ۱۴۰۳ دریافت و در تاریخ ۱۷ آذر ماه ۱۴۰۴ بازنگری شد.

محسن مهدوی اصل، دانشکده مهندسی کامپیوتر، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران، (email: mahdaviasl.mohsen@gmail.com).

مارال کلاه کج (نویسنده مسئول)، گروه مهندسی کامپیوتر، واحد سوسنگرد، دانشگاه آزاد اسلامی، سوسنگرد، ایران، (email: maral.kolahkaj@iau.ac.ir).

1. Financial Engineering
2. Data Mining Techniques
3. Forecasting
4. Time Series
5. Artificial Neural Networks

پنهان میان متغیرها را بیاموزند و بر مبنای آن، مقادیر آتی را با دقت قابل‌توجهی پیش‌بینی کنند.

در میان انواع شبکه‌های عصبی، شبکه‌های عصبی کانولوشنی[1] (CNNs) به دلیل قابلیت استخراج خودکار ویژگی‌ها و یادگیری چندلایه، عملکرد درخشانی از خود نشان داده‌اند [۱۷] و [۱۸]. این نوع شبکه با الهام از ساختار قشر بینایی مغز، ارتباطات مکانی میان نورون‌ها را مدل‌سازی کرده و قادر است ویژگی‌های محلی و جهانی داده‌ها را هم‌زمان استخراج نماید [۱۹]. بدین ترتیب، CNNها نقطه‌ی تلاقی میان فرایند استخراج ویژگی[2] و طبقه‌بندی[3] محسوب می‌شوند و بدون نیاز به طراحی دستی ویژگی‌ها، قادر به یادگیری نمایش‌های مؤثر از داده‌ها هستند. کارایی بالای شبکه‌های CNN در مسائل یادگیری عمیق طی سال‌های اخیر در حوزه‌های مختلفی چون پردازش تصویر، تشخیص الگو و پیش‌بینی مالی اثبات شده است [۲۰] تا [۲۳].

با این‌وجود، یکی از چالش‌های اصلی در آموزش شبکه‌های عمیق، تنظیم بهینه‌ی وزن‌ها و پارامترهای مدل است. فرایند یادگیری ممکن است زمان‌بر بوده و در صورت انتخاب نامناسب پارامترها، به همگرایی ضعیف یا گرفتار شدن در بهینه‌های محلی منجر شود. برای رفع این چالش، استفاده از الگوریتم‌های فراابتکاری[4] به‌عنوان ابزارهایی کارآمد در جستجوی فضای بهینه‌سازی پیشنهاد شده است [۲۴] و [۲۵]. در این تحقیق، از ترکیب شبکه عصبی کانولوشنی (CNN) با الگوریتم شاهین هریس[5] (HHO) [۲۶] به‌عنوان یک روش ترکیبی نوآورانه جهت بهبود دقت و سرعت پیش‌بینی قیمت سهام استفاده شده است.

هدف از این پژوهش، طراحی مدلی ترکیبی است که بتواند ضمن کاهش پیچیدگی محاسباتی، دقت پیش‌بینی قیمت سهام را در داده‌های سری زمانی افزایش دهد. بدین منظور، از قدرت یادگیری نظارت‌شده‌ی CNN برای مدل‌سازی الگوهای قیمتی و از الگوریتم HHO برای تعیین ماتریس وزن‌های بهینه در هر لایه‌ی کانولوشنی استفاده می‌شود. بدین ترتیب، انتظار می‌رود مدل پیشنهادی ضمن افزایش دقت پیش‌بینی، موجب کاهش زمان آموزش و همگرایی سریع‌تر شبکه شود. شبکه‌ی CNN به طور خاص به این دلیل انتخاب شد که برخلاف LSTM[6]، تمرکز آن بر استخراج ویژگی‌های مکانی و الگوهای کوتاه‌مدت از داده‌های سری زمانی است و برای داده‌های مالی با نوسانات زیاد و وابستگی‌های کوتاه‌مدت عملکرد بهتری دارد.

در نتیجه، دامنه پژوهش حاضر بر بهبود فرایند استخراج ویژگی و همگرایی مدل CNN متمرکز بوده است. به طور خلاصه مشارکت‌های اصلی این مقاله به‌صورت زیر است:

- ارائه‌ی یک مدل ترکیبی نوین برای پیش‌بینی قیمت سهام (CNN+HHO): این تحقیق، یک چارچوب ترکیبی جدید ارائه کرده است که در آن از شبکه عصبی کانولوشنی (CNN) برای استخراج ویژگی‌های مؤثر و پیچیده از داده‌های سری زمانی استفاده می‌شود و سپس الگوریتم شاهین هریس (HHO) برای بهینه‌سازی وزن‌ها و پارامترهای فیلتر شبکه عصبی کانولوشن به‌کار می‌رود. این ادغام موجب بهبود دقت پیش‌بینی و کاهش قابل‌توجه خطای مدل شده است.
- بهینه‌سازی فرآیند یادگیری و همگرایی مدل: برخلاف بسیاری از روش‌های یادگیری عمیق که دچار همگرایی کند یا گیر افتادن در مینیمم‌های محلی می‌شوند، در روش پیشنهادی با استفاده از الگوریتم HHO، مسیر بهینه‌ی یادگیری انتخاب شده و نرخ همگرایی افزایش یافته است. این ویژگی در مقایسه با مدل‌های مرجع کاملاً مشهود است.
- کاهش چشمگیر خطای پیش‌بینی (MSE): این نشان می‌دهد مدل پیشنهادی در پیش‌بینی داده‌های مالی عملکرد بهینه، تعمیم‌پذیر و پایدار دارد.
- ایجاد تعادل میان دقت و پایداری مدل: در مقاله نشان داده می‌شود که علاوه بر افزایش دقت، نوسانات مدل در تکرارهای مختلف کاهش یافته است که بیانگر پایداری عددی و استحکام ساختاری مدل پیشنهادی است؛ ویژگی‌ای که بسیاری از مدل‌های مبتنی بر یادگیری عمیق فاقد آن هستند.
- ارائه تحلیل پیچیدگی محاسباتی جهت بررسی قابلیت استقرار روش پیشنهادی در محیط‌های لبه.

۲- کارهای پیشین

نااطمینانی در مورد آینده‌ی بازار بورس سبب شده است که فعالان این بازار با ابهامات متعددی در خصوص قیمت‌های آتی دارایی‌های پایه مواجه باشند. در گذشته، زمانی که روش‌های مبتنی بر هوش مصنوعی و الگوریتم‌های ابتکاری هنوز توسعه‌نیافته بودند، پیش‌بینی قیمت‌ها معمولاً با استفاده از مدل‌های خطی کلاسیک انجام می‌شد. از جمله‌ی این روش‌ها می‌توان به مدل‌های رگرسیونی، مدل‌های خودرگرسیونی و میانگین متحرک[7] (ARIMA)، روش‌های هموارسازی نمایی و میانگین متحرک ساده اشاره کرد [۲۷]. هرچند این روش‌ها به دلیل سادگی و تفسیرپذیری، در دوره‌ی خود کاربرد گسترده‌ای داشتند، اما محدودیت آن‌ها در مدل‌سازی روابط غیرخطی و پویای موجود در بازارهای مالی، موجب شد که عملکرد آن‌ها در شرایط واقعی بازار محدود باشد.

با پیشرفت چشمگیر روش‌های هوش مصنوعی و محاسبات تکاملی، پژوهشگران به‌تدریج از مدل‌های خطی به سمت مدل‌های غیرخطی و داده‌محور حرکت کردند. امروزه تکنیک‌هایی مانند شبکه‌های عصبی مصنوعی (ANNs)، الگوریتم‌های فراابتکاری و سیستم‌های فازی، در پیش‌بینی سری‌های زمانی مالی به‌طور گسترده مورداستفاده قرار می‌گیرند [۲۸] تا [۳۴]. این روش‌ها قابلیت شناسایی الگوهای پیچیده و روابط پنهان در داده‌های مالی را دارند و در نتیجه دقت پیش‌بینی را به‌طور چشمگیری افزایش داده‌اند. در ادامه، برخی از مطالعات شاخص در این زمینه مرور می‌شوند.

منگ و همکاران [۳۵] با هدف بهبود عملکرد پیش‌بینی نرخ ارز، دو رویکرد مدل‌سازی پارامتری (شبکه‌های عصبی با سلول‌های عصبی فعال) و ناپارامتری (مدل کمپلکس آنالوگ) را مورد بررسی قرار دادند. آن‌ها در پژوهش خود یک روش ترکیبی نوآورانه پیشنهاد کردند که در آن، دو مدل پارامتری و ناپارامتری به‌صورت خودسازمان‌ده[8] و مکمل ترکیب شده‌اند تا

1. Convolutional Neural Networks
2. Feature Extraction
3. Classification
4. Metaheuristic Algorithms
5. Harris Hawks Optimization
6. Long Short-Term Memory
7. Autoregressive Integrated Moving Average
8. Self-organizing

از مزایای هر دو بهره‌مند گردند. نتایج نشان داد که مدل ترکیبی پیشنهادی قادر است نوسانات روزانه‌ی نرخ ارز را با دقت بالاتری نسبت به روش‌های سنتی پیش‌بینی کند.

یوسیم و همکاران [۳۶] با تمرکز بر تحلیل احساسات در اخبار مالی، تأثیر داده‌کاوی را بر پیش‌بینی بازار سهام بررسی کردند. آن‌ها بر این باور بودند که میان اخبار و تغییرات قیمت سهام، رابطه‌ای تنگاتنگ وجود دارد و اخبار می‌توانند تأثیر قابل‌توجهی بر رفتار سرمایه‌گذاران داشته باشند. در این راستا، آن‌ها یک چارچوب داده‌کاوی مبتنی بر پردازش زبان طبیعی[1] (NLP) برای تحلیل اخبار به زبان کره‌ای ارائه کردند تا تغییرات شاخص قیمت سهام کره را پیش‌بینی کنند. روش پیشنهادی شامل استخراج ویژگی‌های زبانی، تحلیل احساسات و شناسایی روابط بین محتوای خبری و نوسانات بازار بود. نتایج این پژوهش نشان داد که تحلیل احساسات اخبار می‌تواند در پیش‌بینی نوسانات بازار سهام نقشی مؤثر ایفا کند و به بهبود مدل‌های تصمیم‌گیری مالی کمک نماید.

نتی و همکاران [۳۷] نیز در مطالعه‌ای دیگر، با استفاده از طبقه‌بندی‌کننده‌ی ماشین بردار پشتیبان[2] (SVM)، مدلی برای پیش‌بینی قیمت سهام در بازار بورس هند ارائه دادند. با توجه به پیچیدگی محاسباتی بالای SVM در داده‌های حجیم مالی، پژوهشگران برای بهبود کارایی و سرعت مدل، از ترکیب مراحل انتخاب ویژگی و خوشه‌بندی[3] استفاده کردند. نتایج آن‌ها نشان داد که افزودن این مراحل پیش‌پردازشی موجب بهبود قابل‌توجه در عملکرد و دقت مدل SVM شده است.

در [۳۸]، یک مدل ترکیبی عمیق برای پیش‌بینی قیمت سهام ارائه شده است که از شبکه‌های عصبی کانولوشن (CNN) برای استخراج ویژگی‌های مکانی از شاخص‌های فنی و از شبکه‌های حافظه بلندمدت (LSTM) برای مدل‌سازی وابستگی‌های زمانی در داده‌های سری زمانی استفاده می‌کند. همچنین، از مکانیزم توجه[4] برای تمرکز پویا بر ویژگی‌های مهم‌تر در توالی داده‌ها بهره گرفته است تا دقت پیش‌بینی افزایش یابد. بااین‌حال، ترکیب CNN، LSTM و Attention، مدلی بسیار پیچیده با پارامترهای فراوان ایجاد می‌کند. در داده‌های محدود یا دارای نویز، این موضوع به بیش‌برازش[5] منجر می‌شود و مدل در داده‌های واقعی عملکرد پایداری ندارد. همچنین، در این کار، تنظیم پارامترهای شبکه به‌صورت تجربی یا آزمون‌وخطا انجام شده است. این رویکرد باعث می‌شود مدل از لحاظ کارایی و پایداری بهینه نباشد. این مقاله تنها نتایج مربوط به داده‌های آزمایشی را گزارش می‌دهد و تحلیل پایداری مدل را ارائه نکرده است.

مرجع [۳۹] ترکیبی از LSTM و CNN را برای تحلیل هم‌زمان چند ویژگی به کار می‌گیرد. هرچند مدل LSTM-CNN چندوجهی در مقاله مذکور توانسته با ترکیب ساختارهای زمانی و مکانی، دقت پیش‌بینی قیمت‌های مالی را بهبود دهد، اما این رویکرد به‌دلیل نبود بهینه‌سازی تطبیقی، پیچیدگی زیاد و عدم تحلیل پایداری، محدودیت‌هایی در کاربرد عملی دارد.

جهت بهبود دقت پیش‌بینی قیمت سهام در بازار، مقاله [۴۰]، مدل ترکیبی CNN–LSTM–GNN را با هدف ادغام ویژگی‌های مکانی، زمانی و ساختاری در پیش‌بینی قیمت سهام توسعه داده است. با وجود دقت قابل‌قبول در داده‌های تاریخی، این رویکرد به‌دلیل پیچیدگی محاسباتی بالا، نبود بهینه‌سازی تطبیقی و فقدان تحلیل پایداری، در کاربردهای واقعی و تعمیم‌پذیر با محدودیت مواجه است. این امر باعث افزایش هزینه‌ی آموزش، مصرف بالای حافظه، و خطر بیش‌برازش مخصوصاً در داده‌های مالی پرنویز می‌شود.

به‌طورکلی، مرور مطالعات گذشته نشان می‌دهد که ترکیب روش‌های یادگیری ماشین با الگوریتم‌های بهینه‌سازی و تحلیل داده‌های متنی، به‌ویژه تحلیل احساسات، می‌تواند در پیش‌بینی بازارهای مالی کارآمد باشد. بااین‌حال، هنوز چالش‌هایی نظیر انتخاب ویژگی‌های مؤثر، تنظیم پارامترهای بهینه، و مقابله با نوسانات غیرخطی و غیرایستا در بازار وجود دارد که ضرورت توسعه‌ی مدل‌های ترکیبی و چندهدفه را بیش‌ازپیش نمایان می‌سازد. در پژوهش حاضر، این کاستی‌ها با استفاده از الگوریتم بهینه‌سازی شاهین هریس و طراحی چارچوبی ساده‌تر، دقیق‌تر و پایدارتر برطرف شده است.

۳- روش پیشنهادی

هدف از این پژوهش، ارائه‌ی چارچوبی کارا و دقیق برای پیش‌بینی قیمت سهام در بازار سرمایه ایران است که بتواند محدودیت‌های روش‌های کلاسیک مبتنی بر یادگیری سطحی را برطرف نماید. در روش پیشنهادی، یک معماری ترکیبی مبتنی بر شبکه عصبی کانولوشن (CNN) و الگوریتم فراابتکاری شاهین هریس (HHO) طراحی و پیاده‌سازی شده است تا هم‌زمان از مزایای استخراج خودکار ویژگی‌ها و بهینه‌سازی هوشمند وزن‌ها بهره‌مند گردد.

۳-۱ ایده‌ی اصلی و سؤالات تحقیق

در مدل پیشنهادی، بخش یادگیری عمیق (CNN) مسئول استخراج و یادگیری ویژگی‌های پنهان از داده‌های خام قیمتی است، درحالی‌که الگوریتم HHO در نقش بهینه‌ساز خارجی، وزن‌ها و فیلترهای کانولوشن را به‌گونه‌ای تنظیم می‌کند که سرعت همگرایی افزایش و خطای پیش‌بینی کاهش یابد. بر اساس این منطق، دو سؤال اصلی تحقیق عبارتند از:

- چگونه می‌توان دقت پیش‌بینی قیمت سهام در بازار بورس ایران را با استفاده از شبکه‌های عصبی کانولوشن افزایش داد؟
- آیا به‌کارگیری الگوریتم شاهین هریس در فرایند آموزش CNN می‌تواند موجب کاهش سربار محاسباتی و افزایش سرعت همگرایی شود؟

۳-۲ معماری شبکه عصبی کانولوشن (CNN)

شبکه عصبی کانولوشن مورداستفاده در این پژوهش، بر پایه‌ی مدل‌های الهام‌گرفته از ساختار قشر بینایی مغز طراحی شده است. CNN به‌دلیل قابلیت یادگیری سلسله‌مراتبی از ویژگی‌ها، یکی از مؤثرترین ابزارها در استخراج الگوهای زمانی و مکانی از داده‌های مالی محسوب می‌شود. بر خلاف روش‌های کلاسیک که نیازمند استخراج دستی ویژگی‌های آماری هستند، CNN قادر است این فرایند را به‌صورت خودکار و تطبیقی انجام دهد و ویژگی‌های مؤثر را مستقیماً از داده‌های خام یاد بگیرد.

در طرح پیشنهادی، معماری CNN شامل دو لایه‌ی کانولوشن، دو لایه‌ی Pooling، و یک لایه‌ی کاملاً متصل است که به‌صورت

1. Natural Language Processing
2. Support Vector Machine
3. Clustering
4. Attention Mechanism
5. Overfitting

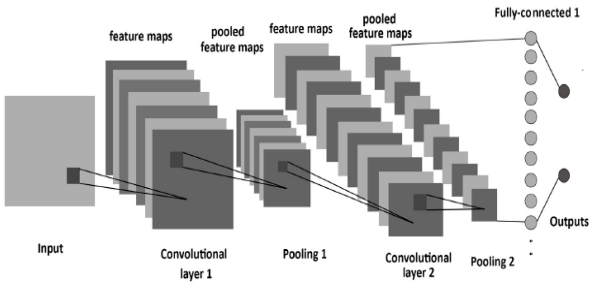

شکل ۱: ساختار شبکه عصبی کانولوشن پیشنهادی برای پیش‌بینی قیمت سهام.

درهم‌گذاری (تکرار دو سطح از ترکیب یک لایه کانولوشن و یک لایه Pooling) طراحی شده است (شکل ۱). لایه‌های Fully Connected مسئول نگاشت ویژگی‌های استخراج‌شده به خروجی نهایی (پیش‌بینی قیمت سهام) هستند.

در بیشتر لایه‌های شبکه از تابع فعال‌سازی ReLU با تعریف $y = \max(x, 0)$ استفاده شده است که نسبت به توابعی نظیر سیگموئید و تانژانت هیپربولیک، سرعت همگرایی بالاتری دارد و از مشکل اشباع گرادیان جلوگیری می‌کند.

۳-۳ بهینه‌سازی CNN با الگوریتم شاهین هریس (HHO)

نوآوری اصلی پژوهش در به‌کارگیری الگوریتم شاهین هریس در فرایند آموزش شبکه عصبی کانولوشن نهفته است. در این رویکرد، HHO به‌عنوان یک بهینه‌ساز هوشمند فرابتکاری برای تنظیم ماتریس‌های وزنی فیلترهای کانولوشن و ضرایب لایه‌های میانی مورداستفاده قرار می‌گیرد.

در آموزش معمول CNN ، وزن‌ها با استفاده از روش پس‌انتشار خطا و بر پایه‌ی گرادیان نزولی به‌روزرسانی می‌شوند. این روش اگرچه مؤثر است، اما در داده‌های مالی که اغلب غیرخطی، پر نویز و ناپایا هستند، با چالش‌هایی نظیر گیرافتادن در کمینه‌های محلی، کندی همگرایی و وابستگی شدید به مقداردهی اولیه مواجه می‌شود.

برای رفع این محدودیت‌ها، در روش پیشنهادی، به‌جای استفاده از وزن‌های اولیه تصادفی برای فیلترهای کانولوشن در هر لایه و بهینه‌سازی آنها از طریق آزمون‌وخطا، از الگوریتم فرابتکاری شاهین‌های قهوه‌ای هریس جهت جستجوی هوشمند در فضای وزن‌های شبکه استفاده شده است. این الگوریتم، یک روش بهینه‌سازی مبتنی بر جمعیت[1] است که از رفتار همکاری و شکار گروهی شاهین‌های هریس در طبیعت الهام گرفته شده است. ویژگی متمایز شاهین‌های هریس، همکاری جمعی در شکار و تغییر تاکتیک‌های حمله بر اساس موقعیت و رفتار طعمه است. در واقع این الگوریتم، با به‌روزرسانی موقعیت هر عامل بر اساس استراتژی‌های تعقیب و حمله، بهترین مجموعه وزن‌ها را برای هر لایه پیدا می‌کند.

شکل ۲ مراحل HHO را نشان می‌دهد که در ادامه توضیح داده شده است.

در طبیعت، این پرندگان به‌صورت گروهی عمل می‌کنند و اغلب نقش‌ها بین اعضا تقسیم می‌شود: برخی شاهین‌ها تعقیب‌کننده هستند، برخی طعمه را محاصره می‌کنند و یک یا چند شاهین با تجربه نقش حمله نهایی را ایفا می‌کنند. این رفتار تطبیقی، الگویی مؤثر برای طراحی یک الگوریتم جستجوی هوشمند ایجاد می‌کند که می‌تواند بین اکتشاف[2] و بهره‌برداری[3] تعادل برقرار نماید.

1. Population-Based
2. Exploration
3. Exploitation

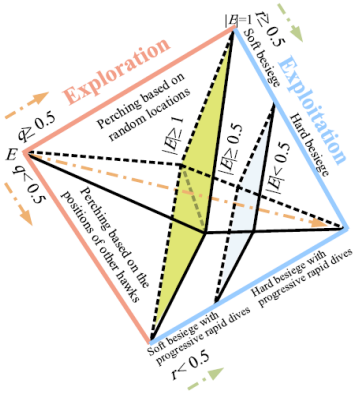

شکل ۲: مراحل مختلف HHO.

Input:
- Population size (N)
- Maximum iterations (T)
- Fitness function: MSE(X)
- CNN model structure

Output:
- Optimal filter weights X_best

1. Initialize population of hawks Xi (i = 1, 2, ..., N)
2. Evaluate fitness of each hawk using MSE(Xi)
3. Select the best hawk X_best as the leader (lowest MSE)

4. For t = 1 to T do
5. Update escaping energy E = 2 * E0 * (1 - t/T)
6. For each hawk Xi:
7. If |E| ≥ 1 then // Exploration phase
8. Update Xi randomly around other hawks
9. Else // Exploitation phase
10. If random () < 0.5 then
11. Perform soft besiege:
Xi = X_best - E * |J * X_best - Xi|
12. Else
13. Perform hard besiege:
Xi = X_best - E * |ΔX|
14. End if
15. Evaluate new fitness of Xi
16. If Fitness(Xi) < Fitness(X_best) then
17. X_best = Xi
18. End if
19. End for
20. Return X_best

شکل ۳: شبه‌کد الگوریتم HHO.

در فرایند HHO، جمعیت اولیه از شاهین‌ها به‌عنوان مجموعه‌ای از راه‌حل‌های ممکن[4] تعریف می‌شود که در اینجا، هر راه‌حل متناظر با ماتریس فیلتر وزن‌دهی کانولوشن است. هدف، یافتن بهترین ترکیب وزن‌ها است که تابع برازش[5]، در اینجا بر اساس معیار *MSE*، را کمینه کند. در این مدل، هر شاهین یک بردار وزن (فیلتر) را نمایش می‌دهد

$$X_i = [w_1, w_2, \ldots, w_n] \quad (1)$$

4. Candidate Solutions
5. Fitness Function

۰	۲	۱	۴	۲	۰	۰	۰

شکل ۴: راه حل در روش فرااِبتکاری شاهین هریس.

که در آن n تعداد عناصر ماتریس فیلتر و w_i وزن‌های متناظر است. تابع برازش به‌صورت (۲) تعریف می‌شود

$$Fitness(X_i) = MSE(X_i) = \frac{1}{N}\sum_{j=1}^{N}(y_j - \hat{y}_j(X_i))^2 \qquad (۲)$$

که در آن $\hat{y}_j(X_i)$ خروجی مدل CNN با استفاده از فیلتر وزن‌دهی X_i است. هدف الگوریتم کمینه‌سازی مقدار MSE است.

بنابراین، در فاز دوم آموزش مدل پیشنهادی، الگوریتم HHO وظیفه انتخاب و بهینه‌سازی پنجره‌های وزنی[1] را بر عهده دارد (شکل ۳). برای سازگاری با تغییر اندازه فیلترها، فیلترهای مختلف با ابعاد متفاوت در یک ماتریس اسپارس با اندازه ثابت تعبیه می‌شوند؛ به‌گونه‌ای که مقادیر خارج از ناحیه فیلتر فعال صفر در نظر گرفته می‌شوند. نمونه‌ای از این ماتریس وزنی به‌عنوان یک راه‌حل مسئله پس از یکسان‌سازی ابعاد در شکل ۴ نشان داده شده است.

در هر تکرار، HHO فیلترهای جدیدی تولید می‌کند، عملکرد آنها بر اساس MSE شبکه CNN ارزیابی می‌شود و در نهایت بهترین فیلتر به‌عنوان وزن بهینه انتخاب می‌گردد. به‌کارگیری HHO در بهینه‌سازی وزن‌های فیلتر کانولوشن موجب می‌شود تا روش پیشنهادی:

- به‌سرعت به حداقل خطای MSE همگرا شود،
- از وابستگی به وزن‌های اولیه تصادفی رها گردد،
- و در نتیجه، دقت پیش‌بینی نهایی مدل CNN در تعیین قیمت سهام به طور چشمگیری افزایش یابد.

در نهایت در فاز سوم، تشخیص قیمت‌های سهام در ماه‌های آتی بر اساس مدل آموزش‌دیده مبتنی بر شبکه عصبی کانولوشن انجام می‌شود و هر داده بعد از خروج از لایه‌های کانولوشن و پولینگ (که فیلترهای آن خروجی مرحله بهینه‌سازی است) به لایه کاملاً متصل نگاشت می‌شود تا بر اساس ماکزیمم مقدار عضویت به‌دست‌آمده به یک دسته از پیش تعیین شده (بازه‌های قیمت) نسبت داده شود. به‌صورت خلاصه، فرایند آموزش مدل پیشنهادی شامل مراحل زیر است:

- مقداردهی اولیه وزن‌ها و فیلترهای CNN با مقادیر تصادفی.
- اجرای الگوریتم HHO برای جستجوی مجموعه وزن‌های بهینه با حداقل MSE روی داده‌های آموزشی.
- جایگزینی وزن‌های بهینه‌ی یافته‌شده در شبکه CNN و ادامه آموزش با روش گرادیان نزولی برای تنظیم نهایی.
- ارزیابی مدل آموزش‌دیده با داده‌های آزمایشی جهت سنجش دقت پیش‌بینی.

این ترکیب باعث می‌شود فرایند آموزش، علاوه بر بهره‌مندی از ساختار سلسله‌مراتبی CNN، از هوشمندی الگوریتم HHO برای فرار از کمینه‌های محلی و دستیابی به همگرایی سریع‌تر و پایدارتر برخوردار شود

٤- پیاده‌سازی و ارزیابی روش پیشنهادی

٤-١ محیط شبیه‌سازی و داده‌های استفاده‌شده

به‌منظور پیاده‌سازی و ارزیابی مدل پیشنهادی، از محیط نرم‌افزاری MATLAB استفاده شده است. مشخصات سخت‌افزاری و نرم‌افزاری سیستم مورد استفاده برای اجرای شبیه‌سازی در جدول ۱ ارائه شده است.

جدول ۱: مشخصات سیستم جهت پیاده‌سازی روش پیشنهادی.

عامل	مشخصات
ریزپردازنده	Intel Core i۵
حافظه RAM	۴ GB
سیستم عامل	Windows 10

داده‌های مورداستفاده در این پژوهش مربوط به قیمت سهام شرکت بهمن خودرو، یکی از شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران است. بازه زمانی داده‌ها از تاریخ ۱۳۸۰/۰۱/۱۸ تا ۱۳۹۹/۲۳/۱۲ را در بر می‌گیرد. این مجموعه‌داده شامل اطلاعات روزانه سهام از جمله تعداد تراکنش‌ها، حجم معاملات، ارزش معاملات، قیمت دیروز، اولین قیمت، آخرین قیمت، قیمت پایانی، کمترین و بیشترین قیمت است [۴۱] و است [۴۲].

٤-٢ پیش‌پردازش داده‌ها

به‌منظور آماده‌سازی داده‌های خام قیمت سهام شرکت بهمن خودرو برای استفاده در مدل پیشنهادی، مجموعه‌داده اولیه شامل ۴۲۵۰ رکورد روزانه و ۱۲ ویژگی عددی ابتدا تحت مجموعه‌ای از مراحل پیش‌پردازش قرار گرفت تا داده‌ها به شکلی مناسب برای یادگیری شبکه عصبی کانولوشن (CNN) تبدیل شوند. این مراحل به شرح زیر است:

- پاک‌سازی داده‌ها[2]: ابتدا رکوردهای ناقص و پرت که شامل مقادیر صفر یا منفی در قیمت و حجم معاملات بودند حذف شدند. همچنین، مقادیر گمشده در داده‌ها با استفاده از میانگین متحرک پنج‌روزه جایگزین گردید تا روند طبیعی تغییرات قیمتی حفظ شود.
- انتخاب ویژگی‌های مؤثر[3]: از میان ۱۲ ویژگی اولیه، تنها سه ویژگی کلیدی شامل حجم معاملات، ارزش ریالی معاملات و قیمت پایانی به‌عنوان متغیرهای ورودی انتخاب شدند. این ویژگی‌ها بیشترین همبستگی را با رفتار قیمتی سهام داشته و برای پیش‌بینی‌های مبتنی بر یادگیری عمیق کارآمدتر هستند.
- نرمال‌سازی داده‌ها[4]: به‌منظور هم‌مقیاس‌سازی متغیرها و جلوگیری از بروز ناپایداری گرادیان در طول آموزش، تمامی داده‌ها با استفاده از روش Min–Max Normalization در بازه‌ی [۰,۱] نرمال‌سازی شدند. این نرمال‌سازی موجب شد که وزن‌دهی شبکه به‌طور متعادل بین متغیرها توزیع گردد و فرایند یادگیری سریع‌تر همگرا شود.
- تبدیل سری زمانی به داده‌ی ماتریسی[5]: برای مدل‌سازی پویایی قیمت سهام، از پنجره لغزان با اندازه‌ی ۳۰ روز استفاده شد. در این روش، اطلاعات ۳۰ روز متوالی به‌عنوان یک ورودی (ویژگی‌های مستقل) و مقادیر سه‌گانه‌ی مربوط به روز اول ماه بعد، به‌عنوان خروجی (برچسب وابسته) در نظر گرفته شدند. بدین ترتیب، مجموعه‌داده‌ی نهایی با ابعاد ۳۰×۳×۱۴۱ تشکیل گردید که در آن هر نمونه شامل ۳۰ مشاهده‌ی زمانی از سه ویژگی اصلی است.

1. Convolution Filters

2. Data Cleaning
3. Feature Selection
4. Normalization
5. Sliding Window Transformation

- تفکیک داده‌ها: داده‌ها به دو بخش داده‌های آموزش[1] و داده‌های آزمون[2] تقسیم شدند: ۷۰ درصد نمونه‌ها برای آموزش مدل و ۳۰ درصد برای آزمون و ارزیابی مورد استفاده قرار می‌گیرند. این تقسیم‌بندی با هدف اطمینان از عدم هم‌پوشانی داده‌های آموزش و تست و بررسی تعمیم‌پذیری مدل انجام شد.
- ساختار ورودی شبکه CNN: خروجی مرحله‌ی پیش‌پردازش، داده‌هایی با ساختار سه‌بعدی بود که مستقیماً به‌عنوان ورودی شبکه‌ی کانولوشن به کار رفت. بدین ترتیب، هر ورودی شامل سه کانال ویژگی[3] در طول ۳۰ گام زمانی است که شبکه در لایه‌های کانولوشن برای یادگیری الگوهای زمانی و همبستگی بین ویژگی‌ها به‌صورت ماتریسی آن را پردازش می‌کند.

فرایند پیش‌پردازش فوق، با هدف افزایش کیفیت داده‌ها، حذف نویز و استخراج الگوهای زمانی- ویژگی مؤثر انجام گرفت تا شبکه CNN بتواند در مراحل بعدی، اطلاعات پنهان موجود در نوسانات قیمتی را به‌طور مؤثرتری یاد بگیرد. این ساختار سه‌بعدی داده‌ها، زمینه را برای ترکیب بهینه با الگوریتم شاهین هریس (HHO) فراهم کرده و موجب بهبود همگرایی، کاهش خطای پیش‌بینی و افزایش پایداری مدل در آزمایش‌های متوالی شد. پارامترهای اصلی مورداستفاده در فرایند پیاده‌سازی در جدول ۲ آورده شده‌اند.

جدول ۲: مشخصات سیستم جهت پیاده‌سازی روش پیشنهادی.

پارامتر شبیه‌سازی	مقدار
تعداد کل رکوردهای دیتاست نهایی	۱۴۱
تعداد ویژگی‌های انتخابی	۳
اندازه مجموعه‌داده آموزشی	۷۰
اندازه مجموعه‌داده تست	۳۰
اندازه جمعیت در روش HHO	۲۰
تعداد دورهای تکرار در روش HHO	۱۰

٤-۳ معیارهای ارزیابی روش پیشنهادی

از آنجاکه برچسب نمونه‌ها (ارزش سهام) به‌صورت مقادیر عددی پیوسته است، لذا نمی‌توان از پارامترهای صحت[4]، فراخوانی[5] و معیار-F۱[6] استفاده نمود؛ بنابراین از شاخص‌های دقت و MSE[7] با رابطه‌های زیر استفاده خواهیم نمود.

$$Accuracy = ۱ - ClassificationError \quad (۳)$$

مقدار خطای *MSE*، تفاوت بین مقدار خروجی مدل و مقدار واقعی آن است.

$$MSE = \frac{۱}{N}\sum_{k=۱}^{n}(Y_k - F_k)^۲ \quad (۴)$$

در (۴)، F_k، مقادیر مشاهده‌شده، Y_k، مقادیر برآوردشده و k تعداد داده‌ها می‌باشند.

٤-٤ روش های مورد مقایسه

برای ارزیابی عملکرد مدل پیشنهادی، نتایج آن با چندین روش مرجع در حوزه پیش‌بینی قیمت سهام مقایسه شده است. این روش‌ها شامل مدل‌های ترکیبی مبتنی بر یادگیری ماشین و الگوریتم‌های الهام‌گرفته از طبیعت هستند که در مطالعات پیشین مورداستفاده قرار گرفته‌اند. در ادامه، خلاصه‌ای از مهم‌ترین این روش‌ها ارائه می‌شود.

- طرح پایه اول " پیش‌بینی قیمت سهام با استفاده از شبکه‌های عصبی کانولوشن در یک سری زمانی چندمتغیره"

در مطالعه‌ی مهتاب و همکاران [۴۳]، یک رویکرد ترکیبی برای پیش‌بینی قیمت سهام بر اساس روش‌های یادگیری ماشین و یادگیری عمیق ارائه شده است. در این پژوهش، از داده‌های شاخص NIFTY ۵۰ مربوط به معاملات بورس ملی هند (NSE) طی سال‌های ۲۰۱۵ تا ۲۰۱۸ استفاده شده است. نویسندگان مدل‌های متعددی بر مبنای رویکردهای یادگیری ماشین ایجاد کرده و سپس از آنها برای پیش‌بینی مقدار «قیمت پایانی» شاخص NIFTY ۵۰ در سال ۲۰۱۹ با افق پیش‌بینی پنج‌روزه بهره گرفته‌اند. نتایج این مطالعه نشان داد که مدل مبتنی بر شبکه عصبی کانولوشنی (CNN) قادر است الگوهای پنهان موجود در داده‌های مالی را با دقت بالاتری نسبت به مدل‌های سنتی شناسایی نماید.

- طرح پایه دوم "بهینه‌سازی پرتفوی میانگین واریانس با استفاده از پیش‌بینی قیمت سهام مبتنی بر یادگیری ماشین"

چن و همکاران [۴۴] مدلی ترکیبی برای پیش‌بینی قیمت سهام و انتخاب پرتفوی بهینه ارائه کرده‌اند. در این رویکرد، دو مرحله اصلی درگیر است: ۱) پیش‌بینی قیمت سهام با استفاده از ترکیب الگوریتم XGBoost و الگوریتم کرم شب‌تاب بهبودیافته (IFA) که در آن الگوریتم IFA برای تنظیم و بهینه‌سازی ابرپارامترهای مدل XGBoost به‌کاررفته است. ۲) انتخاب پرتفوی بهینه با بهره‌گیری از مدل میانگین- واریانس (MV) به‌منظور شناسایی سهامی با بازده بالقوه‌ی بالاتر. نتایج حاصل از این پژوهش نشان داد که استفاده از مدل ترکیبی XGBoost–IFA موجب بهبود دقت پیش‌بینی و کارایی تصمیم‌گیری در انتخاب سبد سرمایه‌گذاری می‌شود.

- طرح پایه سوم "ترکیب بهینه‌سازی گرگ خاکستری[8]- مدل شبکه عصبی المان برای پیش‌بینی قیمت سهام"

در مطالعه‌ی [۴۵]، یک مدل ترکیبی برای پیش‌بینی قیمت سهام ارائه می‌دهد که در آن از ساختار LSTM برای یادگیری وابستگی‌های زمانی سری‌های مالی استفاده شده و یک مکانیزم Attention (ATT) برای تمرکز بر ویژگی‌ها و بازه‌های زمانی مهم‌تر به مدل افزوده شده است. به‌منظور بهبود عملکرد و تنظیم بهینه هایپرپارامترهای شبکه، از الگوریتم فراابتکاری GWO استفاده شده است. در این چارچوب، پارامترهای کلیدی مدل مانند نرخ یادگیری و تعداد نرون‌ها را بهینه‌سازی می‌کند تا خطای پیش‌بینی کاهش یابد. نتایج تجربی نشان می‌دهد که مدل پیشنهادی GWO-LSTM-ATT در مقایسه با مدل‌های پایه مانند LSTM سنتی، دقت بالاتر و خطای پیش‌بینی کمتری در داده‌های بازار سهام ارائه می‌دهد.

1. Training Set
2. Test Set
3. Feature Channels
4. Precision
5. Recall
6. F-Measure
7. Mean Square Error
8. Grey Wolf Optimization (GWO)

- طرح پایه چهارم "ترکیب CNN-LSTM مبتنی بر توجه"

در [۴۰] یک مدل ترکیبی عمیق برای پیش‌بینی قیمت سهام ارائه کرده است (HCLA) که از شبکه‌های عصبی کانولوشن برای استخراج ویژگی‌های مکانی از شاخص‌های فنی، و از شبکه‌های حافظه بلندمدت (LSTM) برای مدل‌سازی وابستگی‌های زمانی در داده‌های سری زمانی استفاده می‌کند. همچنین، از مکانیزم توجه برای تمرکز پویا بر ویژگی‌های مهم‌تر در توالی داده‌ها بهره گرفته است.

٤-٥ تحلیل دقت و ساختار مدل پیشنهادی در پیش‌بینی قیمت سهام

برای ارزیابی عملکرد مدل پیشنهادی و مقایسه آن با روش‌های موجود، ابتدا لازم است دقت پیش‌بینی هر روش بر روی مجموعه‌داده بررسی شود. در گام نخست، از شبکه عصبی پرسپترون چندلایه (MLP) برای پیش‌بینی قیمت آتی سهام استفاده شد. در این مرحله، ویژگی‌هایی با ابعاد ۳×۳۰ که وضعیت سهام در ماه‌های گذشته را نشان می‌دهند، به‌عنوان ورودی شبکه در نظر گرفته شدند و خروجی شبکه نیز بیانگر قیمت پیش‌بینی‌شده سهام بود.

در فرایند آموزش، شبکه عصبی با تنظیم وزن‌ها و پارامترهای داخلی خود به‌گونه‌ای یاد می‌گیرد که اختلاف بین قیمت پیش‌بینی‌شده و مقدار واقعی به حداقل برسد. به بیان دیگر، مدل تلاش می‌کند خطای پیش‌بینی را کاهش دهد تا توانایی تعمیم آن به داده‌های جدید افزایش یابد. پس از آموزش، عملکرد مدل با استفاده از داده‌های آزمایشی مورد ارزیابی قرار گرفت تا دقت نهایی شبکه مشخص شود.

در مدل پایه پیاده‌سازی شده، شبکه عصبی شامل یک لایه ورودی با ۹۰ نرون، سه لایه پنهان و یک لایه خروجی با یک نرون است. این ساختار برای یادگیری روابط غیرخطی بین متغیرهای ورودی و قیمت سهام به کار گرفته شده است.

در مرحله بعد، برای بهبود عملکرد، از شبکه عصبی کانولوشن استفاده شد. در این مدل، ویژگی‌های اولیه با کمک الگوریتم فراابتکاری شاهین هریس بهینه‌سازی شدند. الگوریتم HHO وظیفه دارد تا فیلترهای وزنی بهینه را برای لایه‌های کانولوشن تعیین کند، به‌گونه‌ای که شبکه بتواند از داده‌های تاریخی سهام، ویژگی‌های مؤثرتر و معنادارتری استخراج نماید.

به‌این‌ترتیب، ویژگی‌های اولیه پس از عبور از لایه‌های کانولوشن و پولینگ به مجموعه‌ای از ویژگی‌های فشرده‌تر و غنی‌تر تبدیل می‌شوند. همان‌گونه که در شکل ۵ نشان‌داده‌شده است، مدل نهایی شامل ۲۹ ویژگی استخراج‌شده است که به لایه‌ی کاملاً متصل منتقل می‌شوند. در این بخش، سه لایه پنهان وظیفه ترکیب این ویژگی‌ها و انجام پیش‌بینی نهایی قیمت سهام را بر عهده دارند.

در مجموع، ترکیب CNN با الگوریتم HHO باعث بهبود قابل‌توجهی در فرایند یادگیری ویژگی‌ها، افزایش دقت پیش‌بینی و کاهش خطای مدل نسبت به روش‌های کلاسیک مانند MLP شده است.

٤-٦ نتایج آزمایش

در این بخش، شبیه‌سازی به تعداد ۵ بار تکرار شد تا از پایداری و قابلیت اطمینان نتایج اطمینان حاصل شود. برای مقایسه عملکرد روش پیشنهادی، سه روش پایه به‌عنوان معیار در نظر گرفته شدند:

- پیش‌بینی مبتنی بر یادگیری عمیق (Deep Learning) [۴۳]،
- پیش‌بینی مبتنی بر الگوریتم بهینه‌سازی کرم شب‌تاب تطبیقی(IFA) [۴۴]،

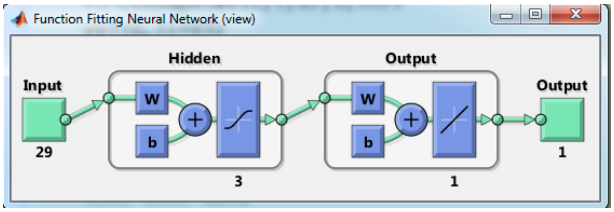

شکل ۵: شمای شبکه عصبی استفاده شده در طرح پیشنهادی پس از اعمال کانولوشن.

جدول ۳: مقایسه عملکرد روش پیشنهادی بر اساس مقدار خطای MSE.

روش	MSE
Deep Learning	۳۱۰
IFA	۲۸۰
GWO	۹۰
LSTM	۲۶۰
CNN+LSTM	۲۱۰
HCLA	۱۵۰
CNN+HHO (پیشنهادی)	۵۰

- پیش‌بینی مبتنی بر الگوریتم گرگ خاکستری (GWO) [۴۵].
- پیش‌بینی مبتنی بر شبکه عصبی کانولوشن و LSTM (HCLA) [۴۰].

معیار اصلی مورداستفاده در این بخش، میانگین مربعات خطا (MSE) است. این شاخص بیانگر اختلاف بین مقادیر واقعی و مقادیر پیش‌بینی‌شده است. هر چه مقدار MSE کمتر باشد، مدل از دقت و کیفیت پیش‌بینی بالاتری برخوردار است.

بر اساس نتایج ارائه‌شده در جدول ۳، عملکرد مدل پیشنهادی (ترکیب شبکه عصبی کانولوشنی با الگوریتم شاهین هریس – CNN+HHO) نسبت به سایر روش‌های مقایسه‌شده، به‌طور قابل‌توجهی برتر است. همان‌گونه که مشاهده می‌شود، مقدار خطای میانگین مربعات در روش پیشنهادی برابر با ۵۰ است که کمترین مقدار در میان تمام مدل‌ها محسوب می‌شود. این امر نشان‌دهنده‌ی دقت بالاتر و پایداری بیشتر مدل در فرایند پیش‌بینی است. به‌طور خاص:

مدل Deep Learning به‌عنوان یک چارچوب پایه مبتنی بر یادگیری عمیق، مقدار خطای ۳۱۰ را به دست آورده است که بیانگر محدودیت آن در همگرایی بهینه در داده‌های پیچیده و غیرخطی است.

الگوریتم IFA با کاهش خطا به ۲۸۰، اندکی بهبود نسبت به یادگیری عمیق نشان می‌دهد، اما همچنان از دقت مطلوب برخوردار نیست.

روش GWO (بهینه‌سازی گرگ خاکستری) با مقدار ۹۰، عملکرد بهتری نسبت به دو روش قبل دارد و نشان می‌دهد که الگوریتم‌های فراابتکاری می‌توانند نقش مؤثری در تنظیم پارامترهای مدل ایفا کنند.

مدل LSTM با خطای ۲۶۰ نشان می‌دهد که اگرچه در تحلیل وابستگی‌های زمانی توانمند است، اما در استخراج ویژگی‌های مکانی و پیچیده ضعیف‌تر عمل کرده است.

ترکیب CNN+LSTM با مقدار ۲۱۰ توانسته است بخشی از این ضعف را جبران کند، زیرا ترکیب ویژگی‌های مکانی (CNN) و وابستگی زمانی (LSTM) به بهبود نسبی دقت منجر شده است.

مدل HCLA نیز با مقدار خطای ۱۵۰ نسبتاً عملکرد مناسبی دارد و نشان می‌دهد که ترکیب چند الگوریتم و استفاده از مکانیزم توجه می‌تواند تا حدی باعث بهبود مدل شود.

جدول ۴: سربار محاسباتی طرح پیشنهادی و طرح های پایه در پیش‌بینی قیمت سهام.

روش	تأخیر [ثانیه]
Deep Learning	۰٫۳۱
IFA	۰٫۲۹
GWO	۰٫۳۰
CNN+HHO (پیشنهادی)	۰٫۲۸

در نهایت، مدل پیشنهادی CNN+HHO با مقدار خطای ۵۰، بهترین عملکرد را میان تمام روش‌های مقایسه‌شده ارائه داده است. این بهبود چشمگیر ناشی از توانایی شبکه‌های عصبی کانولوشنی (CNN) در استخراج ویژگی‌های محلی و چندسطحی از داده‌ها و همچنین قابلیت جست‌وجوی بهینه و تطبیق‌پذیری بالای الگوریتم شاهین هریس (HHO) در تنظیم وزن‌ها و پارامترهای شبکه است.

علاوه بر کاهش خطا، نتایج شبیه‌سازی نشان داده‌اند که روش پیشنهادی از نظر پایداری و تعمیم‌پذیری نیز برتر است؛ به این معنا که در تکرارهای مختلف آزمایش، نوسانات خطا کمتر بوده و مدل توانسته است الگوهای پنهان داده‌ها را به‌صورت باثبات‌تری شناسایی کند. این ویژگی‌ها باعث می‌شوند که مدل CNN+HHO نه‌تنها برای داده‌های آموزشی بلکه برای داده‌های اعتبارسنجی و آزمون نیز عملکرد قابل‌اطمینان‌تری داشته باشد.

در مجموع، می‌توان نتیجه گرفت که ترکیب CNN و HHO با ایجاد تعادل میان استخراج ویژگی مؤثر و بهینه‌سازی هوشمندانه پارامترها، رویکردی دقیق، پایدار و کارآمد برای پیش‌بینی متغیرهای پیوسته؛ مانند قیمت سهام ارائه کرده است.

۴-۷ سربار محاسباتی و پیچیدگی زمانی روش پیشنهادی

در این بخش، به بررسی سربار محاسباتی و پیچیدگی زمانی هر یک از روش‌های مورداستفاده در پیش‌بینی قیمت سهام پرداخته شده است. هدف از این تحلیل، ارزیابی تأثیر به‌کارگیری الگوریتم فرابتکاری شاهین هریس (HHO) در ترکیب با شبکه عصبی کانولوشن (CNN) بر زمان اجرای کل سیستم است. به‌طور خاص، پرسش اصلی آن است که آیا افزودن این الگوریتم منجر به افزایش زمان محاسباتی و در نتیجه کاهش کارایی می‌شود یا برعکس، به بهبود سرعت اجرای مدل کمک می‌کند.

بر اساس نتایج ارائه‌شده در جدول ۴، میانگین تأخیر اجرای مدل پیشنهادی (CNN+HHO) برابر با ۰٫۲۸ ثانیه است که از تمامی روش‌های پایه شامل Deep Learning (۰٫۳۱ ثانیه)، IFA (۰٫۲۹ ثانیه) و GWO (۰٫۳۰ ثانیه) کمتر می‌باشد. این کاهش زمان اجرا بیانگر آن است که استفاده از الگوریتم شاهین هریس نه‌تنها باعث افزایش پیچیدگی محاسباتی نشده، بلکه به بهینه‌سازی روند آموزش و پیش‌بینی کمک کرده است.

علت اصلی این بهبود را می‌توان در کاهش ابعاد داده‌ها در لایه‌های پولینگ شبکه عصبی کانولوشن جستجو نمود. با کاهش ابعاد ویژگی‌ها در این لایه‌ها، حجم داده‌های ورودی به مراحل بعدی کاهش‌یافته و در نتیجه زمان لازم برای آموزش مدل و انجام محاسبات به‌طور محسوسی کمتر می‌شود.

به‌طورکلی، نتایج نشان می‌دهد که مدل پیشنهادی CNN+HHO ضمن حفظ دقت پیش‌بینی بالا، از منظر پیچیدگی زمانی نیز بهینه‌تر عمل کرده است و می‌تواند در کاربردهای بلادرنگ مانند تحلیل سریع تغییرات بازار سهام، مورداستفاده مؤثرتری قرار گیرد.

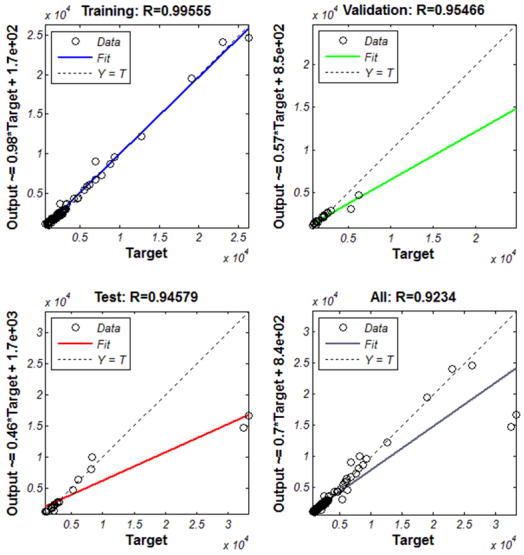

شکل ۶: نمودار رگرسیون مربوط به فازهای مختلف روش پیشنهادی.

۴-۸ تحلیل پایداری و اعتبارسنجی روش پیشنهادی

در این بخش، علاوه بر ارائه نتایج کمی، تحلیل پایداری مدل نیز از طریق نمودار رگرسیون نمونه‌های واقعی در برابر نمونه‌های پیش‌بینی‌شده در شکل ۶ ارائه شده است. باید توجه داشت که هر چه ضریب رگرسیون به عدد یک نزدیکتر باشد، یعنی روش، خطای کمتری دارد و عملکرد طرح مطلوب‌تر خواهد بود. به عبارت دیگر، اگر نقاط روی نمودار نزدیک به خط رگرسیون $y = x$ باشند، مدل عملکرد دقیقی دارد. بررسی این نمودار برای داده‌های آموزش/ اعتبارسنجی/ آزمون به‌صورت جداگانه، تحلیل پایداری بین فازها را نشان می‌دهد.

نمودار رگرسیون نشان می‌دهد که ضرایب همبستگی بین مقادیر واقعی و پیش‌بینی‌شده در مجموعه‌های آموزش، اعتبارسنجی و آزمون به ترتیب برابر با ۰٫۹۹، ۰٫۹۵ و ۰٫۹۴ بوده است، که بیانگر تعمیم‌پذیری و پایداری مناسب مدل پیشنهادی است. نتایج این تحلیل‌ها نشان می‌دهد که توزیع خطاها متمرکز و متقارن بوده و مقادیر ضریب همبستگی در سه مرحله نزدیک به یک است. این امر نشان‌دهنده‌ی پایداری، همگرایی مناسب و تعمیم‌پذیری بالا در مدل CNN–HHO است.

۵- نتیجه‌گیری و کارهای آتی

پیش‌بینی قیمت سهام در فرایند سرمایه‌گذاری از اهمیت ویژه‌ای برخوردار است، زیرا به‌عنوان یکی از عوامل کلیدی در ارزیابی ارزش سهام تلقی می‌شود و در بسیاری از موارد نقش تعیین‌کننده‌ای در تصمیم‌گیری‌های سرمایه‌گذاران دارد. ازاین‌رو، ارائه الگوهای نوین و دقیق برای پیش‌بینی قیمت سهام می‌تواند نقش مؤثری در بهبود کیفیت تصمیم‌گیری‌های مالی ایفا کند.

در روش پیشنهادی این پژوهش، برای پیش‌بینی قیمت سهام در بازار بورس از شبکه عصبی کانولوشن (CNN) بهبودیافته با بهره‌گیری از الگوریتم بهینه‌سازی شاهین هریس (HHO) استفاده شده است. بدین ترتیب، به‌منظور ایجاد مدلی با دقت بالا در تشخیص و پیش‌بینی قیمت سهام، از قابلیت یادگیری نظارت‌شده در شبکه عصبی کانولوشن بهره گرفته شد تا فرایند استخراج ویژگی‌ها در لایه‌های میانی شبکه جایگزین روش‌های دستی استخراج ویژگی گردد.

در مرحله دوم، برای آموزش مدل نظارت‌شده، انتخاب پنجره‌های وزنی

مورداستفاده در عملیات کانولوشن بر عهده الگوریتم شاهین هریس قرار داده شد. ازآنجاکه ابعاد راه‌حل‌ها در الگوریتم‌های فراابتکاری معمولاً ثابت هستند و مقادیر آن‌ها از طریق عملگرهای درونی الگوریتم تغییر می‌کند تا به‌تدریج به سمت راه‌حل بهینه حرکت نمایند، در این پژوهش فیلترهای مختلف با اندازه‌های گوناگون درون ماتریسی وزنی و اسپارس با ابعاد ثابت (برابر با حداکثر اندازه فیلتر) قرار داده شدند. خانه‌های غیر متناظر با موقعیت فیلترها مقدار صفر در نظر گرفته شدند تا ساختار ماتریس از نظر محاسباتی بهینه و کارآمد باقی بماند.

نتایج حاصل از بررسی‌ها و مقایسه عملکرد مدل پیشنهادی با روش‌های پایه نشان می‌دهد که ترکیب شبکه عصبی کانولوشن با الگوریتم بهینه‌سازی شاهین هریس منجر به افزایش چشمگیر دقت پیش‌بینی قیمت سهام و کاهش قابل‌توجه خطای میانگین مربعات (MSE) شده است. بدین ترتیب، مدل پیشنهادی توانسته عملکردی دقیق‌تر و پایدارتر نسبت به روش‌های مرسوم ارائه دهد.

در گام‌های آتی پژوهش، هدف ما ارائه مدلی است که با استخراج ویژگی‌های جدید و مؤثر در تعیین قیمت سهام بتواند وضعیت آتی بازار بورس را با دقت بیشتری توصیف کرده و هم‌زمان پیچیدگی زمانی محاسبات را در طرح فعلی کاهش دهد. در این راستا، می‌توان از سایر شبکه‌های عصبی مانند LVQ و RBF استفاده کرده و نتایج را به‌صورت تطبیقی مورد تحلیل و ارزیابی قرار داد. از سوی دیگر، بهره‌گیری از روش‌های فراابتکاری چندهدفه نظیر الگوریتم گرگ خاکستری چندهدفه (MOGWO) برای آموزش مدل‌های پیش‌بینی، می‌تواند به توسعه چارچوبی هوشمندتر و کارآمدتر در تحلیل و پیش‌بینی بازار سهام منجر شود. همچنین، در این پژوهش مدل پیشنهادی برای پیش‌بینی عددی قیمت سهام طراحی شده است. بااین‌حال، در مطالعات آینده می‌توان خروجی مدل را به‌صورت دودویی (افزایش یا کاهش قیمت) تعریف نمود و عملکرد آن را با معیارهای دقت طبقه‌بندی، صحت، فراخوانی و معیار-F۱ نیز ارزیابی کرد تا دید جامع‌تری نسبت به جهت حرکت قیمت سهام حاصل شود. در تحقیقات آینده، روش پیشنهادی می‌تواند با مدل‌های یادگیری عمیق مانند LSTM و Transformer مقایسه و یا تلفیق شود تا پایداری و دقت آن در داده‌های زمانی بررسی گردد.

مراجع

[1] E. D. O. Carosia, A. E. A. da Silva, and G. P. Coelho, "Predicting the Brazilian stock market with sentiment analysis, technical indicators and stock prices: A deep learning approach," *Computational Economics*, vol. 65, pp. 23512378, 2025.

[2] M. Kolahkaj, A. Harounabadi, and M. Sadeghzade, "A recommender system for web mining using neural network and fuzzy algorithm," *International Journal of Computer Applications*, vol. *78,* no. 8, pp. 20-24, Sept 2013.

[3] A. Hemmati, H. M. Arzanagh, and A. M. Rahmani, "A taxonomy and survey of big data in social media," *Concurrency and Computation: Practice and Experience*, vol. 36, no. 1, Article ID: e7875, Jan. 2024.

[4] M. J. Awan, *et al.*, "Social media and stock market prediction: A big data approach," *Computers, Materials & Continua*, vol. 67, no. 2, pp. 2569-2583, 2021.

[5] W. Landis, S. Cha, and M. Shaalan, "On optimization of stock market prediction methods," in *Proc. IEEE Int. Conf. Big Data*, pp. 6116-6118, Los Angeles, CA, USA,9 -12 Dec. 2019.

[6] M. Nabipour, P. Nayyeri, H. Jabani, A. Mosavi, and E. Salwana, "Deep learning for stock market prediction," *Entropy*, vol. 22, no. 8, Article ID: 840, Aug 2021.

[7] D. Selvamuthu, V. Kumar, and A. Mishra, "Indian stock market prediction using artificial neural networks on tick data," *Financial Innovation*, vol. 5, no. 16, 12 pp., 2019.

[8] X. Pang, Y. Zhou, P. Wang, W. Lin, and V. Chang, "An innovative neural network approach for stock market prediction," *The Journal of Supercomputing*, vol. 76, pp. 2098-2118, 2020.

[9] M. N. Ashtiani and B. Raahmei, "News-based intelligent prediction of financial markets using text mining and machine learning: A systematic literature review," *Expert Systems with Applications*, vol. 217, Article ID: 119509, May 2023.

[10] S. T. Z. de Pauli, M. Kleina, and W. H. Bonat, "Comparing artificial neural network architectures for Brazilian stock market prediction," *Annals of Data Science*, vol. 7, 613-628, 2020.

[11] S. Deng, Y. Zhu, Y. Yu, and X. Huang, "An integrated approach of ensemble learning methods for stock index prediction using investor sentiments," *Expert Systems with Applications, pt. A,* vol. 238, Article ID: 121710, Mar. 2024.

[12] X. Li, P. Wu, and W. Wang, "Incorporating stock prices and news sentiments for stock market prediction: A case of Hong Kong," *Information Processing & Management*, vol. 57, no. 5, Article ID: 102212, Sept. 2020.

[13] T. J. Strader, J. J. Rozycki, T. H. Root, and Y. H. J. Huang, "Machine learning stock market prediction studies: Review and research directions," *Journal of International Technology and Information Management*, vol. 28, no. 4, pp. 63-83, 2020.

[14] A. Moghar and M. Hamiche, "Stock market prediction using LSTM recurrent neural network," *Procedia Computer Science*, vol. 170, pp. 1168-1173, 2020.

[15] P. Balasubramanian, P. Chinthan, S. Badarudeen, and H. Sriramanm "A systematic literature survey on recent trends in stock market prediction." *Peer J Computer Science*, vol. 10, Article ID: e1700, 2024.

[16] M. Kolahkaj, "An image retrieval approach based on feature extraction and self-supervised learning," in *Proc. 2nd. Int. Conf. on Distributed Computing and High Performance Computing*, pp. 46-51, Qom, Iran, 2-3 Mar 2022.

[17] D. P. Goel, K. Mahajan, N. D. Nguyen, N. Srinivasan, and C. P. Lim, "Towards an efficient backbone for preserving features in speech emotion recognition: deep-shallow convolution with recurrent neural network," *Neural Computing and Applications*, vol. 35, no. 3, pp. 2457-2469, 2023.

[18] C. Szegedy, *et al.,* "Going deeper with convolutions," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognition*, Boston, MA, USA, 7-12 Jun. 2015.

[19] I. K. Nti, A. F. Adekoya, and B. A. Weyori, "A novel multi-source information-fusion predictive framework based on deep neural networks for accuracy enhancement in stock market prediction," *Journal of Big Data*, vol. 8, Article ID: 17, 28 pp., 2021.

[20] S. Bhoite, *et al.*, "Stock market prediction using recurrent neural network and long short-term memory," in *Proc. ICT Infrastructure and Computing: of ICT4SD*, pp. 635-643, Goa, India, 29–30 Jul. 2022.

[21] C. Deng, Y. Huang, N. Hasan, and Y. Bao, "Multi-step-ahead stock price index forecasting using long short-term memory model with multivariate empirical mode decomposition," *Information Sciences*, vol. 607, pp. 297-321, Aug. 2022.

[22] P. Chhajer, M. Shah, and A. Kshirsagar, "The applications of artificial neural networks, support vector machines, and long–short term memory for stock market prediction," *Decision Analytics Journal*, vol. 2, Article ID: 100015, Mar. 2022.

[23] A. Kelotra and P. Pandey, "Stock market prediction using optimized deep-ConvLSTM model," *Big Data*, vol. 8, no. 1, pp. 5-24, Feb. 2020.

[24] M. Kolahkaj, "A hybrid approach for intrusion detection in computer systems using optimized deep neural networks," *Journal of Innovations in Computer Science and Engineering,* vol. 2, Special Issues 4, pp. 70-78, 2025.

[25] M. A. Mohammad, M. Kolahkaj, "Detecting Network Anomalies Using the Rain Optimization Algorithm and Hoeffding Tree-Based Autoencoder," in *Proc. 10th Int. Conf. on Web Research*, pp. 137-141, Tehran, Iran, 24-25 Apr. 2024.

[26] A. A. Heidari, *et al.*, "Harris hawks optimization: Algorithm and applications," *Future Generation Computer Systems*, vol. 97, pp. 849-872, Aug. 2019.

[27] P. R. Patil, D. Parasar, and S. Charhate, "Optimisation-enabled transfer learning framework for stock market prediction," *Journal of Information & Knowledge Management*, vol. 23, no. 2, Article ID: 2450013, 2024.

[28] A. Thakkar and K. Chaudhari, "Fusion in stock market prediction: A decade survey on the necessity, recent developments, and potential future directions," *Information Fusion*, vol. 65, pp. 95-107, Jan. 2021.

indicators," *Engineering, Technology & Applied Science Research*, vol. 15, no. 5, pp. 28012-28017, Oct. 2025.
[39] W. Huang, J. Zhao, and X. Wang, "Model-driven multimodal LSTM-CNN for unbiased structural forecasting of European Union allowances open-high-low-close price," *Energy Economics*, vol. 132, pp. 107459, Apr. 2024.
[40] J. Dong and S. Liang, "Hybrid CNN-LSTM-GNN neural network for A-share stock prediction," *Entropy*, vol. 27, no. 8, pp. 881, Aug. 2025.
[41] http://old.tsetmc.com/Site.aspx?ParTree=111C, [Accessed Oct. 15, 2025].
[42] https://www.nseindia.com/, [Accessed Oct. 15, 2025].
[43] S. Mehtab and J. Sen, Stock Price Prediction Using Convolutional Neural Networks on a Multivariate Time Series, arXiv preprint arXiv:2001.09769, 2020.
[44] W. Chen, H. Zhang, M. K. Mehlawat, and L. Jia, "Mean–variance portfolio optimization using machine learning-based stock price prediction," *Applied Soft Computing,* vol. 100, Article ID: 106943, Mar. 2021.
[45] P. Yan, "Research on stock price prediction based on the GWO-LSTM-ATT model," *Frontiers in Computing and Intelligent Systems*, vol. 3, pp. 107-114, 2024.

محسن مهدوی اصل دانشجوی کارشناسی ارشد رشته مهندسی کامپیوتر در دانشگاه آزاد اسلامی واحد اهواز است. زمینه‌های تحقیقاتی وی شامل یادگیری ماشین و داده‌کاوی می‌باشد.

مارال کلاه‌کج عضو هیأت علمی دانشگاه آزاد اسلامی و پژوهشگر حوزه مهندسی کامپیوتر و هوش مصنوعی است. زمینه‌های پژوهشی وی شامل سیستم‌های توصیه‌گر، الگوریتم‌های بهینه‌سازی و یادگیری ماشین با تمرکز بر تحلیل داده و تصمیم‌گیری هوشمند می‌باشد. از جمله فعالیت‌های پژوهشی او می‌توان به توسعه مدل‌های ترکیبی و گراف‌محور در سیستم‌های توصیه‌گر و به‌کارگیری روش‌های تکاملی در یادگیری عمیق اشاره نمود.

[29] A. Kurani, P. Doshi, A. Vakharia, and M. Shah, "A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting," *Annals of Data Science*, vol. 10, no. 1, pp. 183-208, 2023.
[30] Y. Zhao and G. Yang, "Deep learning-based integrated framework for stock price movement prediction," *Applied Soft Computing*, vol. 133, Article ID: 109921, Jan. 2023.
[31] R. Chiong, Z. Fan, Z. Hu, and S. Dhakal, "A novel ensemble learning approach for stock market prediction based on sentiment analysis and the sliding window method," *IEEE Trans. on Computational Social Systems*, vol. 10, pp. 1-12, Oct. 2022.
[32] A. Ghasemieh and R. Kashef, "An enhanced Wasserstein generative adversarial network with Gramian angular fields for efficient stock market prediction during market crash periods," *Applied Intelligence*, vol. 1, no. 22, pp. 1-22, 2023.
[33] A. Ponmalar and V. Dhanakoti, "An intrusion detection approach using ensemble support vector machine-based chaos game optimization algorithm in big data platform," *Applied Soft Computing*, vol. 116, Article ID: 108295, Feb. 2022.
[34] X. Li, J. Wang, J. Tan, S. Ji, and H. Jia, "A graph neural network-based stock forecasting method utilizing multi-source heterogeneous data fusion," *Multimedia Tools and Applications*, vol. 81, no. 30, pp. 43753-43775, 2022.
[35] S. Meng, et. al., Enhancing Exchange Rate Forecasting with Explainable Deep Learning Models, arXiv preprint arXiv:2410.19241, 2024.
[36] K. Yoosin, S. R. Jung, and I. Ghani, "Text opinion mining to analyze news for stock market prediction," *International Journal of Advanced Soft Computing Applications*, vol. 6, no. 1, pp. 1-13, Mar. 2014.
[37] I. K. Nti, A. F. Adekoya, and B. A. Weyori, "Efficient stock-market prediction using ensemble support vector machine," *Open Computer Science*, vol. 10, no. 1, pp. 153-163, 2020.
[38] H. C. Bhanujyothi and I. J. Jacob, "A hybrid CNN-LSTM attention-based deep learning model for stock price prediction using technical