



An intelligent stock price forecasting model based on deep learning: with dimensionality reduction approach

Shohreh Zokaei¹, Mohammad Reza Sanaei^{*2}, Akbar Mirzapour Babajan³

1- PhD Candidate of Information Technology Management, Department of Information Technology Management, Faculty of Management and Accounting, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

2*- Assistant Professor, Department of economy, Faculty of Management and Accounting, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

3- Assistant professor, Department Economics, Faculty of Management and Accounting, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

Abstract

Forecasting stock price and returns is one of the most complicated and controversial issues in financial markets. The stock market has always been influenced by the state of the national economy, investors' perceptions and political events, and the price series is highly non-linear and unstable. With continuous research and updating of researchers in the economic market and stock market theory, the components of stock price index prediction were gradually exposed and stock price prediction became possible. This research was also conducted with the aim of providing an intelligent stock price forecasting model based on deep learning in the Tehran Stock Exchange market - with the approach of dimensionality reduction techniques for managing the capital portfolio in order to increase returns and reduce investment risk. The data used in the period of 2020-2023 were received from the Kodal system and coded and analyzed using the CRISP method and using the Python programming language. A combination of LSTM, PCA and SVD algorithms was used for the proposed model. Comparing the combination of dimensionality reduction methods with artificial intelligence methods shows that the use of PCA dimensionality reduction method can improve the performance of deep learning compared to other data dimensionality reduction methods.

Keywords: Intelligent model, stock price prediction, deep learning

Citation:

Zokaei, S., Sanaei, M., & Mirzapour Babajan, A. (2024). An intelligent stock price forecasting model based on deep learning: with dimensionality reduction approach. *Journal of Intelligent Marketing Management*, 5(3), 299-324.



مدل هوشمند پیش‌بینی قیمت سهام مبتنی بر یادگیری عمیق: با رویکرد کاهش ابعاد

شهره زکایی^۱، محمدرضا ثنائی^{۲*}، اکبر میرزاپور باباجان^۳

۱- دانشجوی دکتری مدیریت فناوری اطلاعات، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و حسابداری، واحد قزوین، دانشگاه آزاد اسلامی.

۲- استادیار گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و حسابداری، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.

۳- استادیار گروه اقتصاد، دانشکده مدیریت و حسابداری، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.

چکیده

پیش‌بینی قیمت و بازده سهام یکی از پیچیده‌ترین و بحث‌برانگیزترین موضوعات در بازارهای مالی است. بازار سهام همواره تحت تأثیر وضعیت اقتصاد ملی، تصورات سرمایه‌گذاران و رویدادهای سیاسی بوده است و سری قیمت‌ها به شدت غیرخطی و غیرثابت است. با تحقیقات مستمر و به‌روزرسانی محققان در بازار اقتصادی و تئوری بازار سهام، به تدریج مؤلفه‌های پیش‌بینی شاخص قیمت سهام در معرض دید قرار گرفتند و پیش‌بینی قیمت سهام امکان‌پذیر شد. این پژوهش نیز با هدف ارائه مدل هوشمند پیش‌بینی قیمت سهام مبتنی بر یادگیری عمیق در بازار بورس اوراق بهادار تهران - با رویکرد تکنیک‌های کاهش ابعاد جهت مدیریت سبد سرمایه انجام شد تا افزایش بازده و کاهش ریسک سرمایه‌گذاری ممکن شود. داده‌های استفاده‌شده در بازه زمانی ۱۳۹۹ تا ۱۴۰۲ از سامانه کدال دریافت و با استفاده از روش CRISP و با استفاده از زبان برنامه‌نویسی پایتون کدنویسی و تحلیل شدند. برای مدل پیشنهادی ترکیبی از الگوریتم‌های LSTM، PCA، SVD استفاده شد. مقایسه ترکیب روش‌های کاهش ابعاد با روش‌های هوش مصنوعی نشان می‌دهد برای پیش‌بینی برای روز آتی به کارگیری روش کاهش ابعاد PCA می‌تواند عملکرد یادگیری عمیق را نسبت به سایر روش‌های کاهش ابعاد داده بهبود بخشد.

کلیدواژه‌ها: مدل هوشمند، پیش‌بینی قیمت سهام، یادگیری عمیق.

استناد:

زکایی، شهره و ثنائی، محمدرضا و میرزاپور باباجان، اکبر. (۱۴۰۳). مدل هوشمند پیش‌بینی قیمت سهام مبتنی بر یادگیری عمیق: با رویکرد کاهش ابعاد. مدیریت بازاریابی هوشمند، ۵ (۳)، ۲۹۹-۳۲۴.

تاریخ دریافت: ۱۴۰۳/۰۲/۱۰

تاریخ ویرایش: ۱۴۰۳/۰۶/۱۷

تاریخ پذیرش: ۱۴۰۳/۰۷/۲۱

تاریخ انتشار: ۱۴۰۳/۰۸/۲۱

<https://doi.org/JABM.3.2.15564.35125656565047>

نشریه مدیریت بازاریابی هوشمند، ۱۴۰۳، دوره ۵، شماره ۳، پیاپی ۲۵

ناشر: نشریه مدیریت بازاریابی هوشمند

نوع مقاله: علمی پژوهشی

© نویسندگان



مقدمه

بازار سهام نشان‌دهنده یک رویکرد جمعی خرید و فروش ابزارهای مختلف به صورت عمومی و یا خصوصی است (چائودری و تخر، ۲۰۲۱). دلیل اصلی که مردم در بازار سهام سرمایه‌گذاری می‌کنند، به دست آوردن سود است که لازمه آن داشتن اطلاعات درست از بازار و تغییرات سهام و پیش‌بینی روند آینده آن است. بنابراین، سرمایه‌گذار نیازمند ابزارهای لازم قدرتمند و قابل اعتماد است که از طریق آن به پیش‌بینی قیمت سهام بپردازد (ژیانگ، ۲۰۲۱). پیش‌بینی بازار مالی برای سرمایه‌گذاری در بازار سهام و مدیریت ریسک، بسیار بحرانی است. تلاش‌های آکادمیک بسیاری برای کشف روش‌های جدید و شاخص‌های پیش‌بینی جدید در جهت دستیابی به عملکرد بهتر وقف شده است (چن یو، ۲۰۲۲). فعالان بازار سرمایه و پژوهشگران از روش‌های مختلفی برای پیش‌بینی قیمت‌ها استفاده می‌کنند و همواره به دنبال استفاده از مدل‌ها و الگوریتم‌های نوینی هستند که بتوانند با رفع نقایص مدل‌های قبلی، با اطمینان بیشتر از آن بهره‌برند (کهنند و همکاران، ۲۰۲۳). در سال‌های اخیر، پیش‌بینی هوشمند مالی به جهت گیری امیدوارکننده‌ای برای توسعه صنعت مالی تبدیل شده است که می‌تواند تا حد زیادی کارایی مدیریت ریسک مالی و تجزیه و تحلیل تصمیم‌گیری‌های مرتبط را بهبود بخشد (نیو و همکاران، ۲۰۲۰). با این حال به دلیل تصادفی بودن و بی‌ثباتی بازار سهام، درک تغییرات قیمت سهام دشوار است و اغلب برای دولت، تنظیم بازار سهام به‌طور مؤثر و به‌موقع آسان نیست (لیو و لونگ، ۲۰۲۰). بازارهای سهام مالی، روزانه حجم عظیمی از اطلاعات قیمت سهام را تولید می‌کنند و دانش‌پژوهان و ذینفعان برای یادگیری و تسلط بر قوانین پیش‌بینی قیمت سهام بر استفاده از مجموعه داده‌های موجود تمرکز کرده‌اند (کنول، ۲۰۲۲). توجه به تنوع متغیرهایی که می‌توان از آن‌ها برای پیش‌بینی استفاده کرد، مهم است. داده‌های خام قیمت، شاخص‌های فنی که از داده‌های تاریخی بیرون می‌آیند، سایر بازارهای مرتبط با بازار هدف، نرخ ارز، قیمت نفت و بسیاری از متغیرهای دیگر می‌توانند برای پیش‌بینی بازار مفید باشند. متأسفانه، معمولاً تجمع چنین مجموعه متنوعی از اطلاعات به گونه‌ای که یک الگوریتم پیش‌بینی خودکار بازار بتواند از آن‌ها استفاده کند، کار ساده‌ای نیست و از آنجایی که رفتار بازارهای سهام پیچیده، غیرخطی و پرسروصداست، استخراج ویژگی‌هایی که برای انجام پیش‌بینی‌ها به اندازه کافی پر معنی و عمیق باشند، یک چالش اصلی است و به نظر می‌رسد یادگیری عمیق، رویکرد امیدوارکننده‌ای برای آن باشد (هراتی‌زاده و حسین‌زاده، ۲۰۱۹). اگرچه روش‌های کلاسیک یادگیری ماشین عملکرد مثبتی در پیش‌بینی قیمت سهام به دست آورده است، اما توانایی آن برای درک اطلاعات در سطح عمیق‌تر عمومی است که نیاز به بهبود بیشتر دارد (نیو و همکاران، ۲۰۲۰).

مطالعات تحقیقاتی اخیر نشان داده است که مدل‌های پیش‌بینی یادگیری عمیق نتایج دقیق‌تری را در مقایسه با مدل‌های سنتی یادگیری ماشین در بازار مالی تولید می‌کنند. یادگیری عمیق معرف سلسله‌ای از الگوریتم‌هاست که در آن از چندین لایه پردازش اطلاعات به‌ویژه اطلاعات غیرخطی استفاده می‌شود تا بهترین ویژگی‌های مناسب از ورودی خام استخراج شود و از طرفی، بازار سهام دارای سیستمی بسیار پیچیده، غیرخطی و آشوب‌گونه است که تحت تأثیر شرایط سیاسی، اقتصادی و روان‌شناسی است. به همین جهت بررسی این سیستم بسیار دشوار به نظر می‌رسد و از این رو به مرور زمان، پژوهشگران دریافته‌اند که با روش‌های سنتی نمی‌توان یک سیستم پویا و پیچیده را تحلیل کرد و لذا به سمت استفاده از روش‌های هوشمند سوق پیدا کرده‌اند. تعداد بالای متغیرهای ورودی به‌طور معمول باعث افزایش پیچیدگی و به تبع آن کاهش کارایی الگو می‌شود. از این رو، استفاده از تکنیک‌های کاهش ابعاد ورودی، ممکن است به افزایش دقت الگوریتم کمک کند (شریف‌فر و همکاران، ۱۴۰۱). مشکل افزایش ناخواسته ابعاد، مشکل فراگیری است. این مشکل، ناشی از تثبیت اندازه‌گیری و ضبط داده‌هاست که از گذشته وجود داشته است. این مسئله، مشکل جدیدی نیست، ولی اخیراً به دلیل افزایش داده‌ها،

اهمیت بیشتری پیدا کرده است. به کارگیری همه عوامل نه تنها باعث ایجاد مشکلات فنی، بلکه باعث پیچیدگی مدل و افزایش اشتباهات آماری نیز می‌شود. بنابراین استفاده از تکنیک‌های مختلف کاهش ابعاد برای کاهش این خطاها و دسترسی به نتایج بهتر است. در این پژوهش قصد داریم که درخصوص ترکیب انتخاب الگوریتم‌های یادگیری عمیق و روش کاهش بُعد به منظور رسیدن به بالاترین میزان دقت پیش‌بینی قیمت سهام در یک روز آتی به ارزیابی میزان دقت هر یک از ترکیب‌ها و نهایتاً دستیابی به دقیق‌ترین ترکیب بپردازیم. گفتنی است تحقیق حاضر به دلیل مدل‌سازی و اکتشافی بودن فاقد فرضیه است.

پیشینه پژوهش

پیش‌بینی بازار سهام موضوعی حیاتی در بازار سهام جهانی است. به‌طور معمول، پیش‌بینی سهام بازار با پیش‌بینی دقیق روند و قیمت سهام، به منظور افزایش سود معاملاتی، مرتبط است. به دلیل غیرخطی بودن و نوسانی بودن بازار سهام، دستیابی به یک پیش‌بینی دقیق از روند سهام فرایندی چالش‌برانگیز است (جان و لاتا، ۲۰۲۳). به مرور زمان پژوهشگران دریافته‌اند که با روش‌های سنتی نمی‌توان یک سیستم پویا و پیچیده را تحلیل کرد و لذا به سمت استفاده از روش‌های هوشمند سوق پیدا کرده‌اند (شریف فر و همکاران، ۱۴۰۱). برخی افراد بر این باورند که براساس داده‌های تاریخی سهام، آینده قیمت سهام قابل پیش‌بینی است (مالکیل و فاما، ۱۹۷۰). با این حال، پیش‌بینی دقیق از سری‌های زمانی به‌ویژه سری‌های زمانی مالی چندمتغیره به دلیل برخی عوامل پیچیده مانند تصادفی بودن ذاتی سری‌های زمانی همچنان چالش‌برانگیز است (نیو و همکاران، ۲۰۲۰). در پژوهشی (شریف فر و همکاران، ۱۴۰۱) از ترکیب الگوریتم‌های یادگیری عمیق CNN و LSTM استفاده شده است. درخصوص تکنیک‌های کاهش ابعاد فقط از تکنیک PCA استفاده کرده است. نتیجه این مقاله نشان می‌دهد که این الگوریتم ترکیبی عملکرد بهتری نسبت به الگوریتم RNN دارد. در پژوهشی دیگر (بهشتی و همکاران، ۱۴۰۱) به ارائه یک روش پیش‌بینی قیمت روز آینده سهام براساس ساختار شبکه عصبی عمیق با استفاده از داده‌های قیمت، مجموعه‌ای از شاخص‌های فنی و سرتیتر اخبار به‌عنوان ورودی مدل پرداخته شده است. از سه شبکه SVM، MLP و RNN برای ارزیابی مدل استفاده شده است. نتایج نشان می‌دهد که مدل LSTM بالاترین دقت پیش‌بینی را با استفاده از اخبار و داده‌های مالی به‌دست آورده است. همچنین مدل LSTM در مقایسه با شبکه‌های عصبی SVM، MLP، و RNN از عملکرد بهتری برخوردار است. در مقاله خلیلی و همکاران (۱۴۰۰) با عنوان «ارزیابی و اعتبارسنجی معماری بهینه یادگیری عمیق در پیش‌بینی قیمت سهام» (رویکرد الگوریتم حافظه کوتاه‌مدت ماندگار LSTM)، توانای معماری‌های الگوریتم حافظه کوتاه‌مدت ماندگار (LSTM) جهت پیش‌بینی قیمت سهام مورد بررسی قرار گرفته است. علاوه بر این، ضمن طبقه‌بندی عوامل مؤثر بر قیمت سهام، مؤلفه‌های نشان‌دهنده معاملات سهامداران حقیقی و حقوقی به‌عنوان عاملی اثرگذار بر قیمت سهام معرفی و بررسی شده است. برای اجرای مدل از سه گروه داده‌های قیمتی، شاخص‌های تکنیکال و معاملات سهامداران حقیقی و حقوقی استفاده شده است. نتایج تحقیق نشان از عملکرد بهتر معماری LSTM همراه با Out Drop نسبت به مدل ساده آن و همچنین مدل RNN دارد. در این پژوهش نیز خلأ عدم استفاده از تکنیک‌های کاهش ابعاد محسوس است. باباجانی و همکاران (۱۳۹۸)، با رویکرد ترکیبی، با به کارگیری شبکه عصبی بازگشتی مبتنی بر الگوریتم کلونی زنبورعسل مصنوعی (ABC-RNN)، درصدد ارائه مدلی بهینه برای پیش‌بینی قیمت سهام در بورس تهران است. برای این منظور با استفاده از داده‌های سهام پذیرفته شده در بازار اول تابلوی اصلی بورس تهران که طی سال‌های ۱۳۹۰ تا پایان سال ۱۳۹۴ مورد معامله قرار گرفته است، ضمن تعریف مؤلفه‌های تکنیکال و بنیادی متعدد، با به کارگیری فرایند رگرسیون - همبستگی قدم به قدم (SRCS)، مؤلفه‌های مؤثر بر قیمت سهام انتخاب شده و به‌عنوان ورودی مدل تعریف می‌شود. در مرحله بعد، الگوریتم کلونی زنبورعسل مصنوعی (ABC) در یک فضای طراحی پارامتری، برای بهینه کردن وزن‌ها و تورش‌های شبکه عصبی بازگشتی به کار گرفته می‌شود. برای ارزیابی عملکرد مدل، از چندین

معیار برای سهام شرکت‌های پذیرفته شده در بورس تهران استفاده می‌شود. نتایج نشان‌دهنده آن است که استفاده از شبکه عصبی بهینه شده با الگوریتم کلونی زنبور عسل مصنوعی، دقت قابل ملاحظه‌ای در مقایسه با سایر روش‌های پیش‌بینی دارد. در این پژوهش نیز از تکنیک‌های کاهش ابعاد استفاده نشده است. شوشتریان و همکاران (۱۳۹۷)، به طراحی و به کارگیری مدلی برای پیش‌بینی دقیق قیمت فلزات گران‌بها طبق قیمت آن‌ها در طول زمان پرداخته‌اند. در این تحقیق از دو روش LSTM و RNN برای پیش‌بینی قیمت فلزات گران‌بها استفاده شده است. مدل‌سازی‌های متنوعی بر روی داده‌ها انجام گرفته است و نتایج هر کدام مورد بررسی قرار گرفته‌اند. نتایج شبیه‌سازی‌ها براساس شرایط مختلف و در سری‌های زمانی مختلف در پایداری انجام شده و مورد مقایسه قرار گرفته است. نتیجه پژوهش نشان داده است که روش RNN بهتر از روش LSTM عمل می‌کند. در این پژوهش از تکنیک‌های کاهش ابعاد استفاده نشده است. سانگ و همکاران (۲۰۲۳)، در مقاله‌ای با عنوان «احساسات سرمایه‌گذار براساس روش PCA مقیاس شده: پیش‌بینی کننده قوی نوسانات تحقق یافته در بازار سهام چین» به نتیجه می‌رسد که میزان دقت پیش‌بینی کننده ارتباط زیادی با کاهش ابعاد آن دارد. ژنگ و همکاران (۲۰۲۱)، در مقاله‌ای یک مدل پیش‌بینی ترکیبی با ترکیب تجزیه و تحلیل مؤلفه اصلی ارائه کردیم (PCA) و شبکه‌های عصبی بازگشتی (RNN) ارائه می‌کند که در آن قیمت سهام دو نوع صنعت هوافضا (تولیدکننده و اپراتور) بررسی شده است. نتایج نشان می‌دهد که PCA می‌تواند دقت و کارایی پیش‌بینی را بهبود بخشد. ینگ و همکاران (۲۰۲۰)، به مقایسه انواع مدل‌های LSTM، MLP و CNN در خصوص پیش‌بینی شاخص‌های مالی در افق زمانی یک روزه پرداخته است. در نهایت با استفاده از خطای RMSE بهترین عملکرد به ترتیب برای LSTM، CNN و MLP بوده است. سایر پژوهش‌های انجام شده به صورت خلاصه در جدول ۱ آمده است:

جدول ۱: پیشینه پژوهش

شماره مقاله	سال	ابزارها و روش‌ها	نتایج و دستاوردها
سینگا ^{۱۵} همکاران	۲۰۱۹	تحلیل مؤلفه‌های اصلی	مدل هیبردی در سه بُعد مهندسی ویژگی، مدل پیش‌بینی و بهینه‌سازی پارامترهای مدل پیش‌بینی ارائه شده است. نتایج حاکی از خطای ۰٫۶۵ درصدی که عدد بسیار کوچکی است در پیش‌بینی قیمت سهام است.
لانگ ^{۱۶} همکاران	۲۰۱۹	تحلیل مؤلفه اساسی کرنل محور رگرسیون ماشین بردار پشتیبان.	نتایج حاکی از برتری مطلق روش تحلیل مؤلفه اساسی کرنل محور در مهندسی ویژگی قیمت سهام است.
شاندر	۲۰۱۹	مدل آریما (مدل سری زمانی خطی) و قارچ (مدل سری زمانی غیرخطی).	عملکرد مدل هیبرید بهتر از عملکرد تک تک مدل‌ها به صورت مجزا است.
سینگ ^{۱۷} همکاران	۲۰۱۹	مدل رگرسیون ماشین بردار پشتیبان مدل فراابتکاری کرم شب‌تاب	بهینه‌سازی پارامترهای مدل‌ها به افزایش دقت مدل منجر می‌شود.
ژو ^{۱۸} همکاران	۲۰۱۹	الگوریتم جست‌وجوی متوازن شبکه‌های عمیق باور بیزین	نتایج مدل هیبرید نشان‌دهنده برتری آن نسبت به مدل‌های مرجع است.
لیو ^{۱۹} همکاران	۲۰۱۹	الگوریتم یادگیری انتقالی	با استفاده از منطق وزن‌دهی مبتنی بر الگوریتم یادگیری انتقالی ارائه شده، به کاهش ریسک در تصمیم‌گیری‌های مربوط به خرید یا فروش سهام منجر می‌شود.
چن ^{۲۰} همکاران	۲۰۱۹	رویکرد یادگیری تقویتی تئوری گراف	این مدل هیبرید، ساختاری برای ساخت سیستم پیشنهاددهنده ارائه می‌دهد.

یادگیری انتقالی			
ژانگ و همکاران	۲۰۱۹	الگوریتم یادگیری انتقالی الگوریتم یادگیری حافظه کوتاه مدت - بلند مدت	طراحی و معماری این مدل ترکیبی به بهبود قابل توجه در دقت پیش‌بینی سهام‌های با رفتار نامنظم منجر شده است.
پنگ و همکاران	۲۰۱۹	شبکه‌های سلسله‌مراتبی توجه	الگوریتم ارائه شده به پیش‌بینی با دقت بالای رفتارهای هیجانی منجر می‌شود.
چانگ و شین ^{۲۲}	۲۰۱۹	یک مدل ترکیبی ماشین بردار پشتیبان و الگوریتم نزدیک‌ترین همسایگی و الگوریتم نقشه‌های خودسازمانده	این مدل ترکیبی دارای دقت بالا در تشخیص جهت‌گیری‌های سهم (بالارونده، پایین‌رونده) است.
تیاگو و همکاران	۲۰۱۹	الگوریتم عمیق MFNN شبکه‌های حافظه کوتاه مدت - بلندمدت	استفاده از این رویکرد مهندسی ویژگی به افزایش ارزش سهام‌ها در خرید و فروش‌های مبتنی بر این الگوریتم نسبت به الگوریتم‌های دیگر منجر شده است.
بگ اوم و همکاران	۲۰۱۹	خوشه‌بندی ترکیبی مبتنی بر منطق فازی و شبکه‌های عصبی	شاخصی برای افت یا خیزش سهام معرفی شده که هدف محاسبه و تخمین این شاخص با استفاده از منطق نروفازی است. نتایج حاکی از دقت بالای ۹۹ درصد در پیش‌بینی درست افت یا خیزش قیمت سهام شرکت تولید رایانه اپل دارد.
یرین و همکاران	۲۰۲۰	خوشه‌بندی به روش کای - میانگین مدل ترکیبی ماشین بردار پشتیبان با جنگل‌های تصادفی	این رویکرد هیبرید خطای کم‌تری نسبت به مدل‌های مشابه و مرجع دارد.
میشل و همکاران	۲۰۲۰	تبدیلات موجک	با بهبود عملکرد مدل پیش‌بینی در تشخیص نقاط پرت،

یادگیری عمیق حافظه کوتاه مدت -	به افزایش تعمیم پذیری مدل در پیش بینی قیمت سهام	بلندمدت	منجر شود.
گنولینگ ^{۲۷}	۲۰۲۰	شبکه هامبرشین - واینر فازی	این مدل ترکیبی قادر است شیفتهای پویای موجود در داده‌ها را به خوبی پیش بینی و مدل کند.
بوکیچ ^{۲۸}	۲۰۲۰	شبکه‌های عصبی عمیق پیچشی	مدل قادر است رفتارهای مشابه و نقطه تغییر این رفتارها را در گذر زمان شناسایی کند و از این رو، نقاط عطف قیمتی سهام‌ها را پیش بینی نماید.
پائولینا و مسکو ^{۲۹}	۲۰۲۰	تحلیل مؤلفه اساسی	تجزیه سری زمانی به عوامل فصلی، روند و تصادفی و پیش بینی جداگانه هر سری به افزایش دقت مدل عمیق در پیش بینی منجر شده است.
کامینگ ^{۳۰}		تجزیه سری زمانی با الگوریتم CEEMD	
کریستوف ^{۳۱}	۲۰۲۰	الگوریتم ژنتیک با شبکه‌های عصبی عمیق پیچشی	بدون بهینه‌سازی پارامتر کارا در الگوریتم‌های عمیق، امکان دستیابی به دقت بالا وجود نخواهد داشت.
لی ^{۳۲}	۲۰۲۱	رویکرد پروف	نیازمند داده‌های مبتنی بر زمان برای پیش بینی دقیق
همکاران			

روش‌شناسی تحقیق

روش مطالعه در تحقیق حاضر، مطالعه از نوع توصیفی و مدل‌سازی است. در فاز مدل‌سازی، رویکرد موجود، رویکرد DM - Crispien است که شامل گام‌های زیر است:

گام یک:

شناخت ماهیت کسب و کار: شناخت ماهیت سهام و شیوه رفتارها و تعاملات موجود میان بازیگران مختلف، در این مرحله در دستور کار خواهد بود.

گام ۲: شناخت داده:

پس از آنکه بازار بورس مورد نظر انتخاب شد، داده‌ها از منظر مختلف نظیر تمیز بودن، وجود داده‌های پرت، رفتارهای معمول و الگوهای اولیه موجود مورد بررسی قرار می‌گیرد.

گام ۳: آماده‌سازی داده:

داده‌های خام انتخابی در اکثر مواقع مناسب تحلیل نیستند. اگر داده گم شده باشد، باید با استراتژی مناسب پر شود. اگر تبدیلات و نرمال‌سازی نیاز است باید صورت گیرد، اگر لازم باشد از روی ویژگی‌های موجود، ویژگی‌های جدید ایجاد شده یا ویژگی‌های جدید نظیر ایام تعطیلات و ... به داده‌ها الحاق شود و ... این مرحله یک گام مهم و کلیدی در رسیدن به نتایج با دقت بالاست.

گام ۴: مدل‌سازی:

در این مرحله مدل‌سازی اولیه مدل هیبرید یادگیری عمیق در کنار مدل یادگیری انتقالی طراحی و پیاده‌سازی خواهد شد.

گام ۵: ارزیابی:

مدل‌ها باید از نظر شاخص‌هایی نظیر دقت و تعمیم‌پذیری پیش‌بینی مورد مقایسه قرار گیرند تا بهترین مدل انتخاب شود.

گام ۶: جاری‌سازی:

بعد از انتخاب بهترین مدل، باید مدل پیش‌بینی در قالب ساختار خودکار، در یک سیستم تعبیه شود تا در یک فرایند همیشگی پیش‌بینی‌ها به‌دست آید. این ساختار، در قالب یک سیستم پیشنهاددهنده ارائه خواهد شد.

در مرحله مطالعه کتابخانه‌ای، روش گردآوری اطلاعات در این پژوهش به صورت کتابخانه‌ای بوده و مطالب به‌دست آمده حاصل از مطالعه و بررسی کتب، مقالات، پروژه‌های تحقیقاتی، پایان‌نامه‌ها و سایت‌های علمی و فنی است. در بخش داده‌های مربوط به مدل‌سازی، داده‌های مورد استفاده در این پژوهش، داده‌های قیمت سهام‌های مختلف در بازار بورس است. از این رو، این داده‌ها از طریق درگاه‌های الکترونیکی تعبیه شده دریافت خواهد شد. به منظور گردآوری اطلاعات از بانک‌های اطلاعاتی موجود در درگاه‌های داده‌ای بورس (داخلی یا خارجی) استفاده خواهد شد. به منظور تجزیه و تحلیل داده‌ها، مدل‌سازی و ساخت سیستم توصیه‌گر، از نرم‌افزار کدنویسی پایتون استفاده خواهد شد.

مدل ریاضی تحقیق

در این پژوهش هدف استفاده از ترکیب الگوریتم یادگیری عمیق LSTM که در خصوص سری‌های زمانی مالی استفاده می‌شود با تکنیک‌های کاهش بُعد شامل PCA و SVD جهت ارائه مدل پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار است.

پس از مشخص شدن مجموعه شاخص‌های مؤثر بر قیمت سهام، که یکی از اهداف کاربردی این پژوهش است، از تکنیک‌های کاهش ابعاد برای حذف ویژگی‌های نامربوط و اضافی از مجموعه داده‌ها استفاده می‌شود که کارایی مدل‌های یادگیری عمیق را به‌طور چشمگیری افزایش خواهد داد. لذا در ادامه تکنیک‌های کاهش بُعد مورد استفاده در این پژوهش معرفی می‌شود.

کاهش ابعاد با تحلیل مؤلفه‌های اساسی PCA

تجزیه و تحلیل مؤلفه‌های اساسی (PCA) روشی است که تعدادی از داده‌های خام مرتبط را به تعداد کمی از ترکیبات خطی نامرتبط، بدون تغییر دادن ساختار داده‌های نمونه، تبدیل می‌کند. برای کاهش ابعاد و ساده کردن مسائل پیچیده چندبعدی، تعداد کم‌تری از متغیرهایی که اطلاعات داده‌های اساسی را بیشتر منعکس می‌کنند، جایگزین تعداد متغیرهای زیاد می‌شوند.

برای استخراج مؤلفه‌های اساسی، داده‌های اصلی باید استاندارد شوند، بدین معنا که میانگین کرنش کم می‌شود و سپس بر واریانس تقسیم می‌شود تا تأثیر ابعاد مختلف از بین برود.

$$\begin{cases} Y_{ij}^* = \frac{x_{ij} - \bar{x}_j}{s_j} \\ i = 1, 2, \dots, m; j = 1, 2, \dots, n \end{cases} \quad (3-1)$$

سپس ماتریس ضریب هم‌بستگی R محاسبه شده و مقدار ویژه ($i=1, 2, \dots, n$) با حل معادله مشخصه $|\lambda E - R| = 0$ به دست می‌آید.

$$\begin{cases} R = \left[\frac{1}{m-1} \sum_{k=1}^n Y_{ki} \cdot Y_{kj} \right] \\ i = 1, 2, \dots, n; j = 1, 2, \dots, n \end{cases} \quad (2-3)$$

مقدار ویژه λ_i واریانس مؤلفه‌های اساسی است و برای توصیف اطلاعات موجود در جهت بردار ویژگی مربوطه، استفاده می‌شود. بزرگی مقدار ویژگی به‌طور مستقیم منعکس‌کننده تأثیر هر جزء اساسی است. سهم در واریانس یک بردار ویژه، از تقسیم مقدار یک مقدار ویژه بر مجموع همه مقادیر ویژه به دست می‌آید.

i امین مؤلفه اساسی است. $\frac{\lambda_i}{\sum_{k=1}^n \lambda_k}$ نرخ مشارکت تجمعی ابعاد اساسی i قبلی است. بایستی اطمینان حاصل شود که جزء اساسی انتخاب شده حاوی بیشترین اطلاعات از داده‌های اصلی است. در نهایت مقدار بار مؤلفه اساسی محاسبه می‌شود و مقدار امتیاز جزء اساسی به‌عنوان داده‌های آموزشی جدید به دست می‌آید (ژانگ، ۲۰۲۳).

$$\begin{cases} T = p(z_i, x_j) = \sqrt{\lambda_i} a_{ij} \\ i = 1, 2, \dots, m; j = 1, 2, \dots, n \end{cases} \quad (3-3)$$

تجزیه مقدار منفرد SVD

تجزیه SVD اساساً نوعی تجزیه ماتریس است. برای داده‌های سهام، می‌توان آن را به عنوان یک ماتریس $m \times n$ ، که در آن m تعداد رکوردهای داده‌های سهام و n تعداد ویژگی‌های سهام است (برای مثال، ابعاد)، نشان داد.

$$X = \begin{pmatrix} x_{11} & \dots & x_{1n} \\ \vdots & & \vdots \\ x_{m1} & \dots & x_{mn} \end{pmatrix} \quad (3-4)$$

SVD برای تجزیه ماتریس داده سهام به صورت زیر استفاده می‌شود:

$$X = U \Sigma V^T \quad (3-5)$$

$$X^T X = (V S^T U^T) U S V^T = V (S^T S) V^T \quad (3-6)$$

$$X X^T = U S V^T (V S^T U^T) = U (S S^T) U^T \quad (3-7)$$

$$\sigma_i = \sqrt{\lambda_i} \quad (3-8)$$

در معادله (۳-۶)، ماتریس ویژگی $X^T X$ ، در واقع ماتریس V در SVD است. در معادله (۳-۷)، ماتریس ویژگی $X X^T$ ، در واقع ماتریس U در SVD است. در معادله (۳-۸) جذر مقدار ویژه Σ ماتریس برابر است با مقدار ویژه ماتریس $X^T X$. به طور خاص، ماتریس U یک ماتریس منفرد راست $m \times m$ است، ماتریس Σ یک ماتریس $m \times n$ است و ماتریس V یک ماتریس منفرد راست $n \times n$ است.

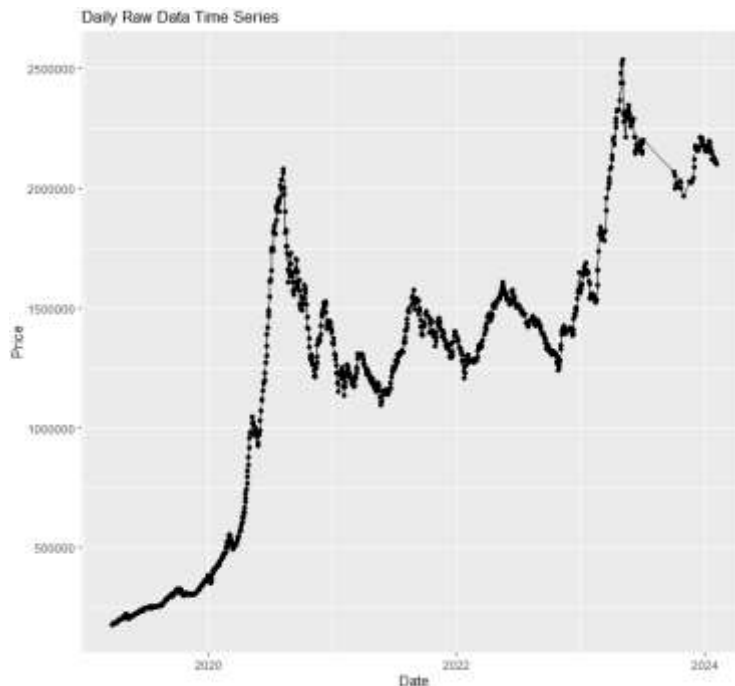
بر اساس SVD، ماتریس X را می‌توان به شکلی تبدیل کرد که در آن سه ماتریس ضرب می‌شوند. این عناصر مورب ماتریس Σ مقادیر منفرد ماتریس X هستند که تقریباً می‌توانند اهمیت ویژگی در ماتریس را منعکس کنند. مقادیر منفرد کوچک در ماتریس را می‌توان نادیده گرفت، زیرا ممکن است نویز باشند (سان و همکاران، ۲۰۲۱).

آمار توصیفی

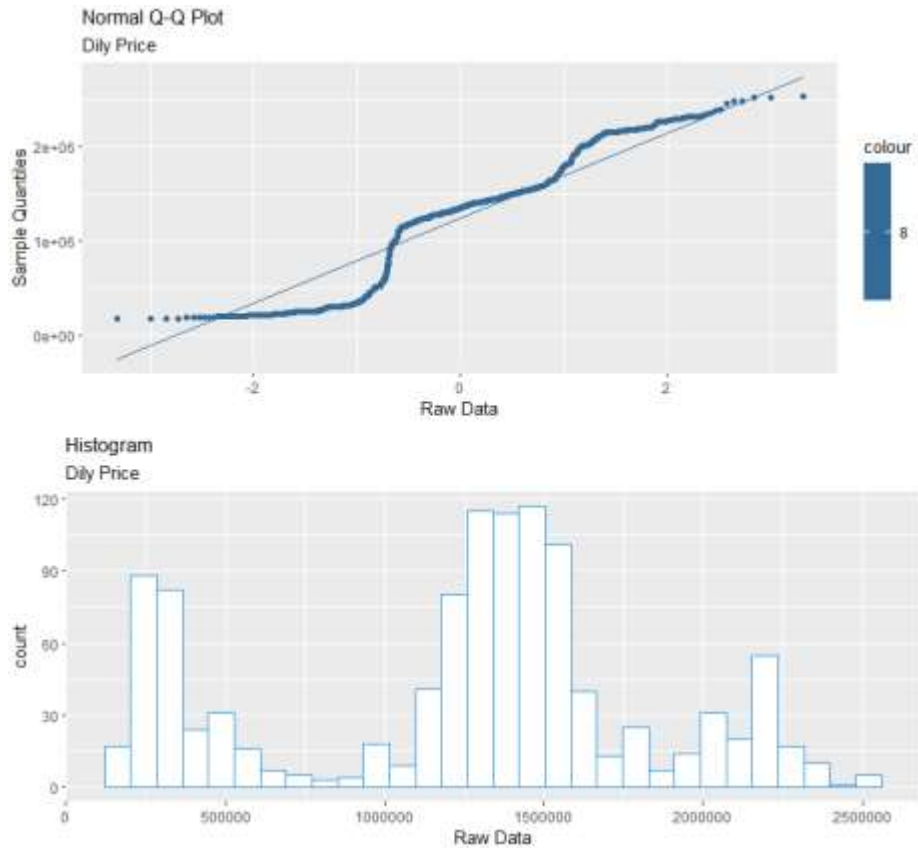
داده‌های گردآوری شده شامل قیمت آغازین، قیمت پایانی، بیشترین قیمت، کمترین قیمت، میزان تغییر و درصد تغییر شاخص کل قیمت بورس تهران در دوره زمانی سال ۱۳۹۸ تا بهمن ماه سال ۱۴۰۲ جامعه آماری ما را تشکیل می‌دهد. داده‌ها به صورت روزانه گردآوری شده و مجموعاً مشتمل بر ۱۱۱۰ مشاهده مربوط به ۱۸۰۰ روز بوده که از این میان داده‌های مربوط به ۳۶ روز که مربوط به متغیر درصد تغییر هستند از نمونه حذف شدند. خلاصه‌ای از وضعیت داده‌های روزانه در جدول ۲ ارائه شده است. همچنین شکل ۲ نمودار تغییرات قیمت در بازه مذکور را نشان می‌دهد.

جدول ۲: مشخصات داده‌های گردآوری شده (منبع: یافته‌های پژوهش)

آماره	قیمت آغازین	قیمت پایانی	بالاترین قیمت	کم‌ترین قیمت	میزان تغییر	درصد تغییر
میانگین	۱,۲۴۲,۴۷۴	۱,۲۳۶,۶۰۳	۱,۲۴۹,۶۴۳	۱,۲۴۳,۴۷۵	۱۳,۳۸۴	۰
انحراف معیار	۵۹۵,۷۹۷	۵۹۱,۸۹۳	۵۹۷,۴۴۴	۵۹۴,۴۲۶	۱۶,۰۲۹	۰
چارک اول	۹۳۸,۷۰۹	۹۲۶,۲۳۰	۹۴۹,۶۰۷	۹۴۳,۱۲۲	۲,۵۲۱	۰
میانه	۱,۳۵۵,۴۶۶	۱,۳۴۴,۹۴۵	۱,۳۶۱,۵۷۲	۱,۳۵۵,۲۹۶	۷,۶۱۹	۰
چارک سوم	۱,۵۴۷,۰۷۶	۱,۵۴۰,۱۸۲	۱,۵۵۲,۷۸۴	۱,۵۴۵,۹۷۴	۱۸,۳۹۵	۰
بیشینه	۲,۵۳۵,۲۳۷	۲,۵۲۷,۵۴۶	۲,۵۴۸,۲۲۷	۲,۵۳۵,۲۳۷	۱۳۲,۹۰۸	۰
کمینه	۱۷۸,۷۸۸	۱۷۸,۷۴۳	۱۷۹,۱۹۴	۱۷۹,۱۹۴	۰	۰
چولگی	۰,۳۰۸۶۵۵۱۸۸-	۰,۳۰۸۰۳۸۹۶۸-	۰,۳۱۱۸۹۸۴۷-	۰,۳۱۱۰۴۴۲۴۹-	۲,۳۰۳۴۲۷۰۹۱	۱,۳۰۳۵۳۶۶۲۳
کشدگی	۰,۶۷۲۱۵۲۱۰۲-	۰,۶۷۱۸۲۴۶۷-	۰,۶۷۱۲۳۹۷۳-	۰,۶۷۰۷۶۴۶۲۷-	۷,۷۸۶۴۲۲۳۳۵	۱,۳۴۵۲۴۵۰۶۹
تعداد داده	۱۱۱۰	۱۱۱۰	۱۱۱۰	۱۱۱۰	۱۱۱۰	۱۱۱۰



شکل ۱: نمودار روزانه سری زمانی قیمت شاخص بورس تهران (منبع: یافته‌های پژوهش)

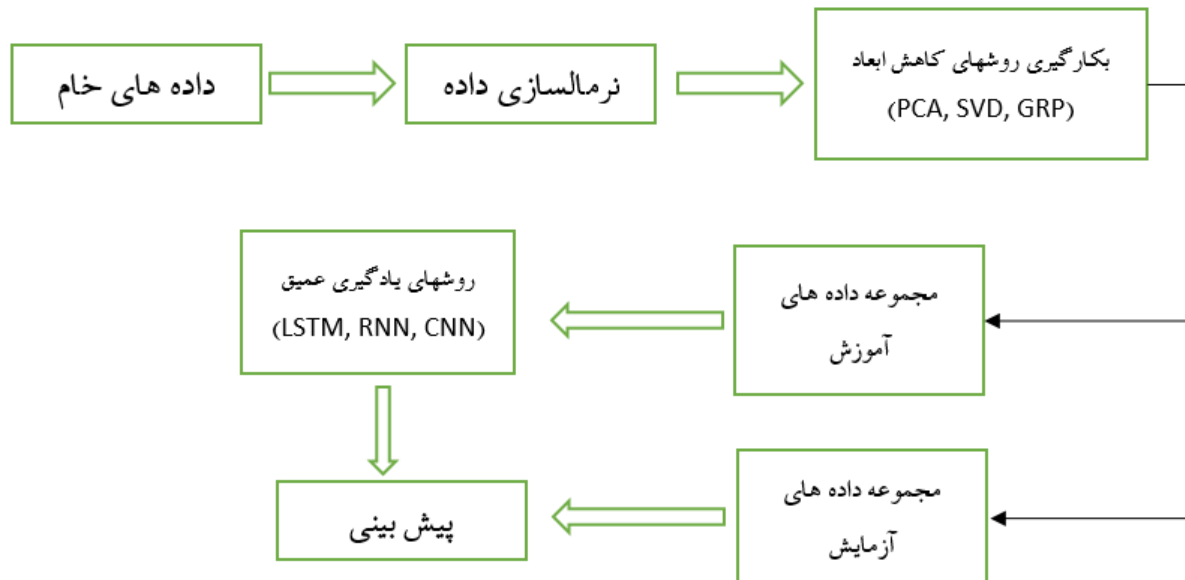


شکل ۲: نمودار Q - Q نرمالیتی و هیستوگرام میانگین قیمت روزانه (منبع: یافته‌های پژوهش)

یافته‌های پژوهش

در این بخش از تحقیق به ارائه نتایج حاصل از مدل‌های پیش‌بینی و بررسی دقت هر مدل می‌پردازیم. بر این اساس دو روش کاهش ابعاد PCA، SVD و الگوریتم یادگیری عمیق LSTM شبکه‌های عصبی طراحی شده و پس از بهینه‌سازی ابرپارامترهای هر مدل، با استفاده از داده‌های ورودی آموزش داده شدند. در نهایت داده‌های آزمایشی به منظور سنجش دقت هر مدل به الگوریتم‌ها داده شده و دقت آن‌ها اندازه گرفته شد.

فرایند الگوریتم پیشنهادی برای پیش‌بینی قیمت سهام براساس روش‌های کاهش ابعاد و الگوریتم‌های یادگیری عمیق در شکل ۴ نشان داده شده است.



شکل ۳: فرایند الگوریتم پیشنهادی (منبع: یافته‌های پژوهش)


تجزیه و تحلیل نتایج کاهش ابعاد

تجزیه و تحلیل مؤلفه اصلی (PCA)

ممکن است بین شاخص‌های فنی مختلفی که بر قیمت سهام تأثیر می‌گذارند هم‌بستگی وجود داشته باشد. در این تحقیق از نرم‌افزار R برای انجام تحلیل مؤلفه‌های اصلی بر روی شش شاخص فنی شامل قیمت بازگشایی، قیمت بالا، قیمت پایین، قیمت پایانی، میزان تغییر و درصد تغییر استفاده شده است. نتیجه تجزیه و تحلیل به صورت جدول ۳ نشان داده شده است. طبق جدول ۳ و مطابق با برآوردهای پژوهش، حدود ۶۹/۴۴ درصد پراکندگی مجموعه داده‌ها توسط مؤلفه اول بازگو شده است. همچنین، حدود ۲۹/۳ درصد پراکندگی توسط مؤلفه دوم تبیین می‌شود. بنابراین، حدود ۹۸/۶۷ درصد پراکندگی مجموعه داده‌ها توسط مؤلفه اول و دوم بازگو شده است. برای انتخاب تعداد مؤلفه‌های هدف بزرگ‌تر یا مساوی ۸۵ درصد تعیین شده است که بنابراین دو مؤلفه اصلی استخراج شده و برای پیش‌بینی قیمت سهام استفاده می‌شود. شکل ۵ تجزیه و تحلیل مؤلفه‌های اصلی مجموعه داده‌ها را نشان می‌دهد.

جدول ۳: نتایج تجزیه و تحلیل مؤلفه‌های اصلی (منبع: یافته‌های پژوهش)

مؤلفه‌ها	مقادیر بردار ویژه			استخراج ویژگی‌های اصلی		
	کل	درصد پراکندگی	مقدار ویژه	کل	درصد پراکندگی	مقدار ویژه
مؤلفه اول	۶۹,۴۴	۶۹,۴۴	۴,۱۷	۶۹,۴۴	۶۹,۴۴	۴,۱۷
مؤلفه دوم	۹۸,۶۷	۲۹,۲۳	۱,۷۵	۹۸,۶۷	۲۹,۲۳	۱,۷۵
مؤلفه سوم	۹۹,۹۹	۱,۳۲	۰,۰۸			
مؤلفه چهارم	۱۰۰,۰۰۰	۰,۰۱	۰,۰۰			
مؤلفه پنجم	۱۰۰,۰۰۰	۰,۰۰	۰,۰۰			
مؤلفه ششم	۱۰۰,۰۰۰	۰,۰۰	۰,۰۰			




شکل ۴: نتایج تجزیه و تحلیل مؤلفه‌های اصلی (منبع: یافته‌های پژوهش)

تجزیه مقدار منفرد (SVD)

تجزیه ارزش منفرد (SVD) یک تکنیک جبر خطی است که برای کاهش ابعاد استفاده می‌شود. هنگامی که SVD را به مجموعه داده خود اعمال می‌کنید، سه ماتریس U ، D و V به دست می‌آید. U دارای M ردیف است که در آن M تعداد ویژگی‌های اصلی است و K ابعاد کاهش یافته است. هر ردیف در U نشان‌دهنده یک ویژگی در فضای اصلی است. ماتریس D ($K \times K$) حاوی مقادیر منفرد است. مقادیر منفرد نشان‌دهنده اهمیت ابعاد مربوطه در فضای کاهش یافته است. آن‌ها به ترتیب نزولی مرتب شده‌اند، بنابراین اولین مقدار در ماتریس بزرگ‌ترین است و الی آخر. مقادیر منفرد میزان توضیح‌دهندگی پراکندگی توسط هر بعد را نشان می‌دهد. V ($K \times N$) ماتریس V دارای K ردیف و N ستون است که N تعداد نمونه‌هاست. هر ردیف در V نشان‌دهنده نمونه‌ای در فضای اصلی است. نتایج جدول ۴ و شکل ۶ نشان می‌دهد که مؤلفه اول حدود ۹۹/۹۹ درصد پراکندگی داده‌ها را بازگو می‌کند.

جدول ۴: نتایج تجزیه مقادیر منفرد (منبع: یافته‌های پژوهش)

مؤلفه‌ها	مقادیر منفرد		استخراج ویژگی‌های اصلی	
	درصد پراکندگی	درصد تجمعی پراکندگی	درصد پراکندگی	تجمعی درصد پراکندگی
مؤلفه اول	۹۹,۹۹۴۰۵	۹۹,۹۹۴۰۵	۹۹,۹۹۴۰۵	۹۹,۹۹۴۰۵
مؤلفه دوم	۹۹,۹۹۷۱۲	۰,۰۰۳۰۷۰۱۷۵		
مؤلفه سوم	۹۹,۹۹۹۵	۰,۰۰۱۹۲۴۰۹		
مؤلفه چهارم	۹۹,۹۹۹۹۵	۰,۰۰۰۹۱۰۲۱۹		
مؤلفه پنجم	۱۰۰,۰۰	۰,۰۰		
مؤلفه ششم	۱۰۰,۰۰	۰,۰۰		

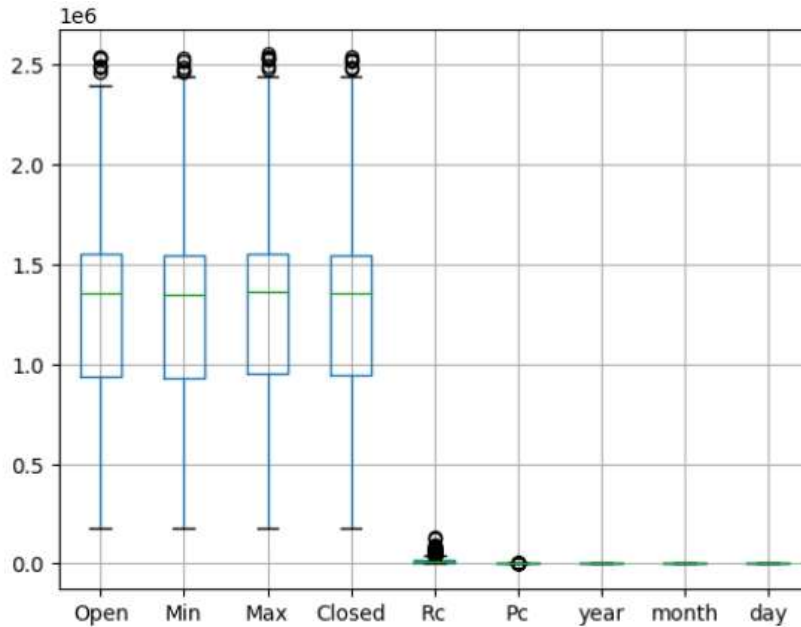


شکل ۵: نتایج تجزیه مقادیر منفرد (منبع: یافته‌های پژوهش)

تجزیه و تحلیل نتایج حاصل از مدل‌های پیش‌بینی نتایج حاصل از مدل LSTM

الگوریتم‌های PCA/LSTM (یک مدل ترکیبی از تحلیل مؤلفه اصلی (PCA) و شبکه‌های عصبی بازگشتی از نوع حافظه بلند کوتاه‌مدت (LSTM))، SVD/LSTM (یک مدل ترکیبی از تجزیه مقادیر منفرد (SVD) و شبکه‌های عصبی بازگشتی از نوع حافظه بلند کوتاه‌مدت (LSTM)) و GRP/LSTM و شبکه‌های عصبی بازگشتی از نوع حافظه بلند کوتاه‌مدت (LSTM)) است. از روش‌های PCA، SVD در این الگوریتم‌ها برای کاهش ابعاد و از LSTM برای پیش‌بینی سری‌های زمانی استفاده می‌شود.

ابتدا، مرحله پیش‌پردازش داده‌ها صورت پذیرفت که عبارت بودند از: ۱. جمع‌آوری و سازماندهی داده‌های خام؛ ۲. بررسی مقادیر گم‌شده و داده‌های پرت؛ و ۳. نرمال‌سازی داده برای یکسان‌سازی ویژگی‌ها که در یک مقیاس باشند. در همین راستا از لگاریتم قیمت‌ها برای مدل‌سازی استفاده شده است.



شکل ۶: نمودار جعبه‌ای برای هر یک از متغیرهای تحقیق (منبع: یافته‌های پژوهش)

در مرحله دوم، برای کاهش ابعاد مجموعه داده از تجزیه و تحلیل مؤلفه اصلی (PCA)، تجزیه مقادیر منفرد (SVD) استفاده شده است. این مرحله به حفظ مهم‌ترین اطلاعات کمک می‌کند و در عین حال ویژگی‌های اضافی یا کم‌تر مهم را حذف می‌کند. برای تعیین تعداد بهینه ویژگی‌ها و متغیرهای توضیحی در هر یک از مرحله سوم، نوبت به تقسیم داده‌ها به مجموعه داده‌های آموزشی و مجموعه داده‌های آزمایشی می‌رسد. در این مرحله از ۸۰ درصد داده‌ها برای آموزش شبکه و از ۲۰ درصد مابقی برای اعتبارسنجی و آزمایش شبکه استفاده شده است.

مرحله چهارم، مرحله طراحی شبکه LSTM است. این مرحله با تعداد ۶ لایه LSTM، تعداد ۵۰ واحد در لایه اول و دوم که در مابین این دو لایه دو لایه (۰،۲) dropout قرار داده شده است. در لایه پنجم تعداد ۵۰ واحد و در لایه آخر از ۱ واحد استفاده شده است تا یک معماری مناسب برای مدل LSTM باشد. در این مرحله می‌بایست شبکه LSTM طوری باشد که مؤلفه‌های به دست آمده از روش‌های کاهش ابعاد را به‌عنوان ورودی کاهش یافته بپذیرد. با استفاده از مجموعه داده آموزشی، مدل LSTM آموزش داده شد. در این مدل از تابع بهینه‌ساز adam و تابع زیان MSE استفاده شده است. تعداد تکرار هر شبکه ۵۰ در نظر گرفته شد. برای جلوگیری از بیش‌برازش آستانه صبر ۵ و اندازه دسته لایه شبکه ۳۲ در نظر گرفته شده است.

در مرحله پنجم برای ارزیابی مدل برای پیش‌بینی از معیارهای میانگین مربعات خطا (MSE)، میانگین خطای مطلق (MAE) و خطای میانگین مربعات ریشه (RMSE) استفاده شده است که در جدول ۵ گزارش شده است.

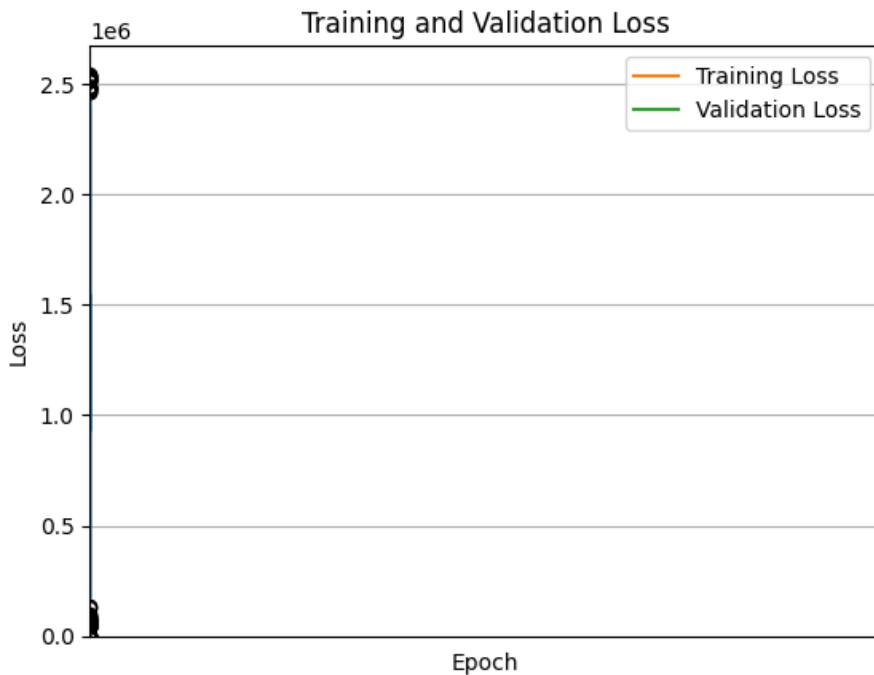
پس از تنظیم شبکه با پارامترهای مذکور، در روش PCA/LSTM و در روش SVD/LSTM در تکرار ۱۲ به نتیجه مطلوب رسیده است.

طبق نتایج ارائه شده در جدول ۵ و مطابق با هر سه معیار ارزیابی خطا RMSE، MAE و MSE، خطای روش PCA/LSTM کم تر از روش SVD/LSTM است.


جدول ۵: خطاها و دقت پیش بینی مدل های ترکیبی کاهش ابعاد و LSTM (منبع: یافته های پژوهش)

الگوریتم	RMSE	MAE	MSE
LSTM_PCA	0.116344	0.094399	0.013536
LSTM_SVD	0.15092	0.120106	0.022777

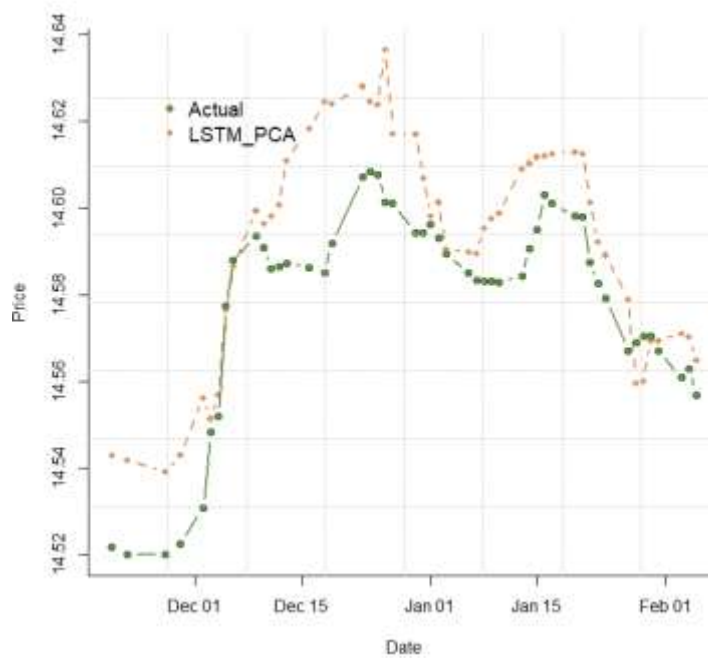
شکل های ۸، ۹ و ۱۰ منحنی قیمت های واقعی مربوط به داده های آزمایشی و مقادیر پیش بینی شده توسط شبکه LSTM را نشان می دهد. با نگاهی به این نمودارها به راحتی می توان دید که منحنی حاصل از مدل PCA/LSTM به منحنی قیمت های واقعی نزدیک تر است.




شکل ۷: نمودار تابع زیان (loss function) برای الگوریتم PCA/LSTM (منبع: یافته های پژوهش)




شکل ۸: ودار پراکنش قیمت پیش بینی شده براساس قیمت واقعی مربوط به مدل PCA/LSTM (منبع: یافته‌های پژوهش)



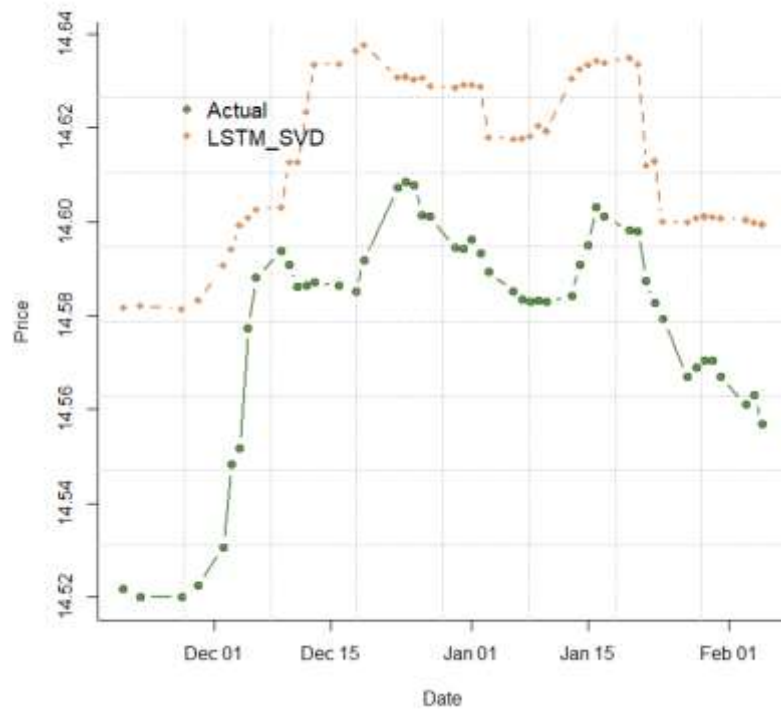
شکل ۹: نمودار قیمت پیش بینی شده توسط مدل (PCA/LSTM) و قیمت واقعی (منبع: یافته‌های پژوهش)



شکل ۱۰: نمودار تابع زیان (loss function) برای الگوریتم SVD/LSTM (منبع: یافته‌های پژوهش)



شکل ۱۱: نمودار پراکنش قیمت پیش‌بینی شده براساس قیمت واقعی مربوط به مدل SVD/LSTM (منبع: یافته‌های پژوهش)



شکل ۱۲: نمودار قیمت پیش‌بینی شده توسط مدل (SVD/LSTM) و قیمت واقعی (منبع: یافته‌های پژوهش)

تحلیل کلی نمودارها

در این بخش به تحلیل نمودارهای حاصل از مدل‌های پیش‌بینی می‌پردازیم. تحلیل نمودارها از آن جهت اهمیت دارد که ممکن است برخی تجزیه و تحلیل‌ها صرفاً با در دست داشتن خطاهای پیش‌بینی قابل دریافت نباشد.

نمودارهای قیمت پیش‌بینی شده و قیمت واقعی توسط مدل‌های تحقیق (اشکال) نشان می‌دهند که مدل PCA/LSTM به دلیل نزدیکی داده‌های پیش‌بینی شده به داده‌های اصلی، پیش‌بینی‌های دقیق‌تری را ارائه داده‌اند. نزدیکی بین مقادیر قیمت پیش‌بینی شده و قیمت واقعی در شکل‌ها نسبت به سایر مدل‌ها پیداست و نشان می‌دهد که به کارگیری روش هوش مصنوعی LSTM با روش‌های کاهش بُعد برای داده بازار سهام ایران از دقت بالاتری برخوردار است و به کارگیری روش کاهش ابعاد PCA می‌تواند عملکرد الگوریتم LSTM را بهبود بخشد.

۱. مقایسه نتایج جدول براساس معیارهای ارزیابی عملکرد مدل، MSE، MAE و RMSE نشان می‌دهد که روش‌های کاهش ابعاد PCA موجب عملکرد بهتر شبکه LSTM می‌شود.
۲. در بین الگوریتم‌های معرفی شده در این تحقیق، الگوریتم PCA/LSTM دارای عملکرد بهتری نسبت به دیگر مدل معرفی شده است.

نتیجه گیری

یافته‌های پژوهش حاضر به تفصیل در قالب جدول‌ها و نمودارها ارائه شد. اکنون به ارائه خلاصه‌ای از نتایج به دست آمده می‌پردازیم. جدول ۶ خلاصه یافته‌های این تحقیق را برای مقایسه راحت‌تر مدل‌های استفاده شده در این تحقیق نشان می‌دهد.

جدول ۶: خطاها و دقت پیش‌بینی مدل‌های ترکیبی کاهش ابعاد (GRP - SVD - PCA) و شبکه‌های هوش مصنوعی (CNN - RNN - LSTM) (منبع: یافته‌های پژوهش)

الگوریتم	RMSE	MAE	MSE
LSTM	0.170869	0.152367	0.029196
LSTM_PCA	0.116344	0.094399	0.013536
LSTM_SVD	0.15092	0.120106	0.022777

با توجه به معیارهای ارزیابی مدل‌های ارائه شده در این تحقیق (جدول ۶) می‌توان نتیجه گرفت که مدل PCA/LSTM پایین‌ترین خطا را در مقایسه با سایر مدل‌ها ارائه می‌دهد. بنابراین پاسخ به این سؤال که آیا روش کاهش ابعاد روی عملکرد الگوریتم یادگیری عمیق اثرگذار است، مثبت است، هرچند که روش‌های کاهش ابعاد با دیگر روش‌های این تحقیق نتایج مثبتی دربر نداشته است. این یافته با یافته‌های شریف‌فر و همکاران (۱۴۰۱) و سانگ و همکاران (۲۰۲۳) همخوانی دارد. مطابق این تحقیقات، مدل پیش‌بینی بر مدل‌های ترکیبی کاهش ابعاد با هوش مصنوعی دقت بالاتری از سایر مدل‌ها دارد.

مقایسه ترکیب روش‌های کاهش ابعاد با روش‌های هوش مصنوعی نشان می‌دهد برای پیش‌بینی برای روز آتی به کارگیری روش کاهش ابعاد PCA می‌تواند عملکرد یادگیری عمیق را نسبت به سایر روش‌های کاهش ابعاد داده بهبود بخشد. این یافته‌ها با نتایج ژنگ و هی (۲۰۲۱) مطابقت دارد.

منابع

شریف‌فر، امیر، خلیلی، مریم، رئیسی وانانی، ایمان، میرفیض فلاح، شمس (۱۴۰۰). کاربرد معماری‌های یادگیری عمیق در پیش‌بینی قیمت سهام (رویکرد شبکه عصبی پیچشی)؛ مدیریت دارایی و تامین مالی، ۳۸، ۱-۲۰.

Bauckhage, C., Kersting, K., Hadiji, F. (2013). Mathematical models of fads explain the temporal dynamics of internet memes, in *Seventh International AAI Conference on Weblogs and Social Media*.

Begüm, D., Lorenzo, B. (2015). A Novel Active Learning Method in Relevance Feedback for Contentbased Remote Sensing Image Retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 53, 5, 2323-2334.

Christoph, K., Rodner, E., Freytag, A., Denzler, J. (2016). Active and Continuous Exploration with Deep Neural Networks and Expected Model Output Changes. *arXiv preprint arXiv:1612.06129*.

- Chung, H., Shin, K. S. (2018). Genetic algorithm - optimized long short - term memory network for stock market prediction. *Sustain*, vol. 10, no. 10.
- Chung, H., Shin, K. S. (2020). Genetic algorithm - optimized multi - channel convolutional neural network for stock market prediction. *Neural Comput. Appl.*, vol. 32, no. 12, 7897–7914.
- Guoliang, H., Li, Y., Zhao, W. (2017). An Uncertainty and Density based Active Semi - supervised Learning Scheme for Positive Unlabeled Multivariate Time Series Classification. *Knowledge - Based Systems*, 124 (2017), 80–92..
- Jiang, W. (2020). Applications of deep learning in stock market prediction: recent progress, Elsevier J., pp. 1–97.
- Kaiming, H., Zhang, X., Ren, Sh., Sun., J. (2016). Deep Residual Learning for Image Recognition.. *In International Conference on Computer Vision and Pattern Recognition*. 770–778.
- Kanwal, A., et al. (2023). BiCuDNNLSTM-1dCNN—A hybrid deep learning-based predictive model for stock price prediction, *Expert Systems With Applications*, vol.202, pp 17-31.
- Li, X., Xie, H., Lau, R. Y. K., Wong, T. L., Wang, F. L. (2018). Stock Prediction via Sentimental Transfer Learning. *IEEE Access*, vol. 6, 73110–73118.
- Lilly, Sh., Gupta, S., Ragavender, N., Anirudh, R. M., Divya, D., (2021). Time Series Model for Stock Market Prediction Utilising Prophet. *Turkish Journal of Computer and Mathematics Education; Trabzon* , 12(6), 4529 -4534.
- Liu, H., Long, Z. (2020). An improved deep learning model for predicting stock market price time series. *Digit. Signal Process. A Rev. J.*, vol. 102, p. 102741.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., et al., (2016). SSD: Single shot multibox detector.. *Lecture notes in computer science (including subseries lecture notes in artificial intelligence and lecture notes in bioinformatics)*.
- Long, W., Lu, Z., Cui, L. (2019). Deep learning - based feature engineering for stock price movement prediction. *Knowledge -Based Syst.*, vol. 164, 163–173.
- Michiel, H. (2013). Encyclopaedia of Mathematics:. *Volume 6: Subject Index Author Index. Springer Science & Business Media*..
- Pang, X., Zhou, Y., Wang, P., Lin, W., Chang, V. (2020). An innovative neural network approach for stock market prediction. *Supercomput.*, vol. 76, no. 3, 2098–2118.
- Paulina, H., Masko, D. (2015). The Impact of Imbalanced Training Data for Convolutional Neural Networks.. *Degree Project in Computer Science, KTH Royal Institute of Technology* .
- Sinaga, F. M., Felix, M. J., Halim, A. (2019). Stock Trend Prediction using SV - kNNC and SOM. *Proc. 2019 4th Int. Conf. Informatics Comput. ICIC 2019*.
- Singh, S., Ahmad, M., Bhattacharya, A., Azhagiri, M. (2019). Predicting stock market trends using hybrid SVM model and LSTM with sentiment determination using natural language processing. *Int. J. Eng. Adv. Technol.*, vol. 9, no. 1, 2870–2875.
- Xu, Y., Yang, C., Peng, S., Nojima, Y. (2020). A hybrid two - stage financial stock forecasting algorithm based on clustering and ensemble learning. *Appl. Intell.*
- Yarin, G., Ghahramani, Z. (2016). Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. *In International Conference on Machine Learning*. 1050–1059.

- Zahedi, M. S., Bokaei, M. H., Shoeleh, F., Yadollahi, M. M., Doostmohammadi, E., Farhoodi, M. (2018). Persian word embedding evaluation benchmarks. *Electrical Engineering (ICEE), Iranian Conference*, pp. 1583–1588,.
- Zhang, G. P. (2007). A neural network ensemble method with jittered training data for time series forecasting. *Inf. Sci.*, 177(23), 5329–5346.
- Zhang, J., Teng, Y. F., Chen, W. (2019). Support vector regression with modified firefly algorithm for stock price forecasting. *Appl. Intell.*, vol. 49, no. 5, 1658–1674.
- Zhang, R., Yuan, Z., Shao, X. (2018). A New Combined CNN - RNN Model for Sector Stock Price Analysis. " *Proc. - Int. Comput. Softw. Appl. Conf.*, vol. 2, 546–551 .
- Zhang, Y., Yan, B., Aasma, M. (2020). A novel deep learning framework: Prediction and analysis of financial time series using CEEMD and LSTM. *Expert Syst. Appl.*, vol. 159, 113609.

¹ Thakkar & Chaudhari

² Jiang

³ Chenyao Ma

⁴ Kehinde

⁵ Niu

⁶ Liu & Long

⁷ Kanwal

⁸ Hoseinzade & Haratizadeh

⁹ John and Latha

¹⁰ Malkiel and Fama

¹¹ Niu

¹² song

¹³ zheng & he

¹⁴ Yengi

¹⁵ Sinaga

¹⁶ Long

¹⁷ Singh

¹⁸ Xu

¹⁹ Liu

²⁰ Chen

²¹ Pang

²² Chung and shik Shin

²³ Thiago

²⁴ Beg`um

²⁵ Yarin

²⁶ Michiel

²⁷ Guoliang

²⁸ Bauckhage

²⁹ Paulina Hensman & David Masko

³⁰ Kaiming

³¹ Christoph

³² Lilly

³³ Cross-industry standard process for data mining

³⁴ Zhang

³⁵ Sun

³⁶ Patience

³⁷ Batch size