

پیش بینی قیمت سهام در بازار سرمایه با رویکرد هوش مصنوعی

عسگر نوربخش^{۱*}، مصطفی شایگانی^۲

تاریخ دریافت: ۱۴۰۳/۰۳/۲۰

تاریخ پذیرش: ۱۴۰۳/۰۵/۲۵

چکیده

هدف این پژوهش پیش بینی قیمت سهام با استفاده از دو نوع شبکه عصبی در بورس اوراق بهادار تهران است. شبکه های عصبی بازگشتی^۳ عموماً در پیش بینی داده های سری زمانی توانایی خوبی دارند، اما شبکه ی عصبی پیچشی^۴ عمدتاً برای کاربردهایی چون بینایی کامپیوتر استفاده می شوند. برای انجام این پژوهش از زبان پایتون در ویرایشگر VS code استفاده شده است. جامعه آماری این پژوهش بورس اوراق بهادار تهران می باشد. حجم نمونه آماری این پژوهش شامل داده های سه نماد بورس اوراق بهادار تهران به شرح ایران خودرو، البرز دارو و توسعه معادن روی ایران است. در این پژوهش از هشت ویژگی قیمت در چارچوب زمانی روزانه از تاریخ ۱۳۸۰ تا تاریخ ۱۴۰۰ استفاده می شود که شامل بالاترین قیمت، پایین ترین قیمت، قیمت بسته شدن، قیمت باز شدن، ارزش معاملات، حجم معاملات، اختلاف قیمت بسته شدن دو روز متوالی، و بازده روزانه است. برای ارزیابی عملکرد مدل ها از سه معیار خطای میانگین خطای مطلق، ریشه میانگین مربعات خطا و ضریب تعیین استفاده شده است. نتایج نشان می دهد که مدل شبکه عصبی پیچشی توانایی پیش بینی با دقت خوبی را دارا می باشد. شبکه های عصبی بازگشتی از بهترین نوع شبکه ها برای پیش بینی قیمت هستند، اما نتایج نشان می دهد که شبکه عصبی پیچشی عملکرد بهتری از شبکه عصبی حافظه کوتاه مدت ماندگار داشته است. نتایج نشان می دهد که مدل های یادگیری عمیق در صورتی که در انتخاب ویژگی هایی (متغیرهای مستقل) که بتوانند بیشترین میزان معناداری را در تفسیر علل فراز و فرودهای قیمت در دوره های رونق و رکود بازار داشته باشند، قابلیت و توانایی پیش بینی قیمت، با دقت قابل قبول را خواهند داشت.

کلمات کلیدی: شبکه عصبی مصنوعی، حافظه کوتاه مدت ماندگار، شبکه عصبی پیچشی، پیش بینی قیمت.

۱. استادیار، گروه مدیریت مالی، دانشکده مدیریت و حسابداری، دانشکده های فارابی دانشگاه تهران، قم، ایران

۲. کارشناسی ارشد مدیریت مالی، دانشکده مدیریت و حسابداری، دانشکده های فارابی دانشگاه تهران، قم، ایران

3 . Recurrent Neural Network (RNN)

4 . Convolutional neural network (CNNs)

مقدمه

تجزیه و تحلیل سری‌های زمانی مالی و پیش‌بینی ارزش‌های آتی قیمت سهام و حرکات آینده آنها، یک حوزه فعال در تحقیقات به مدت طولانی بوده است. در حالی که برخی از پژوهشگران به فرضیه بازار کارآمد اعتقاد دارند و ادعا می‌کنند که تخمین دقیق قیمت سهام امکان‌پذیر نیست، پیشنهادهایی در ادبیات وجود دارد که نشان می‌دهند می‌توان با استفاده از مدل‌های پیش‌بینی دقیق، ارزش‌های قیمت سهام را با سطح بسیار بالایی از دقت پیش‌بینی کرد. همچنین مشاهده شده است که دقت یک مدل پیش‌بینی به مجموعه متغیرهای استفاده شده در ساخت مدل، الگوریتم‌های استفاده شده و نحوه بهینه‌سازی مدل وابسته است. در ادبیات، پیشنهادهایی وجود دارد که بر روی تجزیه و تحلیل سری‌های زمانی برای پیش‌بینی قیمت سهام تمرکز دارند. در حال حاضر، تحلیل بنیادی سنتی و تحلیل تکنیکال هنوز رایج‌ترین روش‌های مورد استفاده برای بسیاری از سازمان‌ها و سرمایه‌گذاران فردی هستند. با توجه به بررسی ادبیات موضوع، شبکه‌های عصبی و یادگیری عمیق در پیش‌بینی قیمت سهام نقش بسیار مهمی ایفا می‌کنند. شبکه‌های عصبی مصنوعی و یادگیری عمیق به عنوان ابزارهای قدرتمند در پیش‌بینی قیمت سهام در بازار بورس مطرح هستند. این روش‌ها با استفاده از الگوریتم‌های هوشمند و پردازش داده‌های تاریخی، الگوهای پنهان در داده‌ها را شناسایی کرده و قادر به پیش‌بینی تغییرات قیمت سهام با دقت بالا هستند. مطالعات نشان می‌دهد شبکه‌های عصبی پیشرو و بازگشتی مانند شبکه‌های عصبی حافظه کوتاه مدت ماندگار می‌توانند به طور موثری روند حرکتی قیمت سهام را پیش‌بینی کنند. با استفاده از این روش‌ها، سرمایه‌گذاران می‌توانند تصمیمات آگاهانه‌تری در بازار سهام اتخاذ نمایند (سعیدی اقدم و همکاران، ۱۴۰۱). نتایج مطالعات انجام شده در این حوزه نشان می‌دهد که شبکه‌های عصبی و یادگیری عمیق با تجزیه و تحلیل دقیق داده‌های تاریخی و شاخص‌های مالی، می‌توانند پیش‌بینی‌های دقیقی در مورد قیمت سهام ارائه دهند. این دقت بالا به سرمایه‌گذاران کمک می‌کند تا تصمیم‌گیری‌های بهتری برای سرمایه‌گذاری


خود بگیرند (مرادی، ۱۴۰۲). پیش‌بینی و مدل‌سازی قیمت همواره امری پرچالش و جز جدایی ناپذیر تحلیل‌های سرمایه‌گذاران بوده، و از طرفی استفاده از شبکه‌های عصبی در امور مالی گسترشی روز افزون داشته است. استفاده از مدل‌های مختلف شبکه‌های عصبی، می‌تواند باعث ایجاد مدل‌های قدرتمند از هر لحاظ در این زمینه شود.

شبکه‌های عصبی بازگشتی (RNN) و به‌ویژه مدل‌های شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) و شبکه‌های عصبی پیچشی (CNN) به عنوان ابزارهای قدرتمند در پیش‌بینی قیمت سهام شناخته می‌شوند. مطالعات نشان می‌دهد که ترکیب این دو مدل با استفاده از داده‌های سری زمانی مختلف می‌تواند دقت پیش‌بینی را افزایش دهد (روحی و رستگار سرخه، ۱۴۰۲). تحقیقات حاکی از آن است که مدل شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) عملکرد بهتری نسبت به مدل ساده شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) و همچنین مدل شبکه عصبی بازگشتی (RNN) دارد. نتایج همچنین، استفاده از توابع فعال‌سازی مناسب مانند tanh در معماری شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) می‌تواند دقت پیش‌بینی را بهبود بخشد (شریف‌فر و همکاران، ۱۴۰۲). در مجموع، این مدل‌های یادگیری عمیق با تحلیل الگوهای پنهان در داده‌ها، قادر به پیش‌بینی تغییرات قیمت سهام با دقت بالا هستند و به سرمایه‌گذاران در اتخاذ تصمیمات آگاهانه‌تر در بازار سهام کمک می‌کنند.

هدف از این پژوهش استفاده از دو شبکه‌های عصبی پیچشی (CNN) و حافظه کوتاه مدت ماندگار (LSTM) است، سوال و مسئله اصلی که در طول این پژوهش به دنبال پاسخ آن هستیم این است که شبکه‌های عصبی تا چه اندازه قابلیت پیش‌بینی قیمت در بازار سرمایه را دارد؟

مبانی نظری تحقیق

الف) شبکه‌ی عصبی: شبکه‌های عصبی، همچنین به عنوان شبکه‌های عصبی مصنوعی^۱ شناخته می‌شوند، مدل‌های محاسباتی هستند که از ساختار و عملکرد مغز انسان الهام گرفته‌اند. آنها برای شناسایی الگوها و تفسیر داده‌ها طراحی شده‌اند، که این امر آنها را به عنوان یک جزء حیاتی از یادگیری ماشین و یادگیری عمیق می‌سازد (شکل ۱). شبکه‌های عصبی برای اولین بار در سال ۱۹۴۴ توسط وارن مک‌کالک^۲ و والتر پیتز^۳، دو پژوهشگر دانشگاه شیکاگو، پیشنهاد شد. آنها یک شبکه عصبی ساده را با استفاده از مدارهای الکتریکی مدل‌سازی کردند تا نشان دهند چگونه نورون‌ها در مغز ممکن است کار کنند. اولین شبکه عصبی قابل آموزش، پرسپترون، توسط روانشناس دانشگاه کارنل، فرانک روزنبلات^۴، در سال ۱۹۵۷ نشان داده شد. در طول سال‌ها، شبکه‌های عصبی تکامل یافته و در زمینه‌های مختلف از تحقیقات علوم اعصاب تا هوش مصنوعی به کار گرفته شده‌اند.



شکل ۱. شبکه عصبی بیولوژیکی (منبع:

[https://rishabh27sharma.medium.com/neural-networks-\(e22cc32fbb45](https://rishabh27sharma.medium.com/neural-networks-(e22cc32fbb45)

تعدادی از انواع شبکه‌های عصبی وجود دارند، هر کدام با معماری و کاربردهای خاص خود:

۱. شبکه‌های عصبی پیشرو^۵: این انواع از ساده‌ترین

شبکه‌های عصبی هستند. اطلاعات از چندین گره ورودی به سمت یک گره خروجی منتقل می‌شوند.

۲. شبکه‌های عصبی کانولوشنی^۶: این انواع به خصوص در بینایی کامپیوتری مفید هستند و در پردازش گفتار و تصویر نیز کاربردهایی دارند.

۳. شبکه‌های عصبی ماژولار^۷: این انواع از چندین شبکه عصبی مختلف تشکیل شده‌اند که مستقل از یکدیگر کار می‌کنند و وظایف زیرگروهی مختلف را انجام می‌دهند.

۴. شبکه‌های عصبی بازگشتی^۸: این مدل پیچیده شبکه عصبی با ذخیره خروجی تولید شده توسط گره‌های پردازنده‌اش و بازگرداندن آنها به الگوریتم عمل می‌کند. این فرآیند امکان بهبود قابلیت‌های پیش‌بینی شبکه‌های عصبی مجازی را فراهم می‌کند.

۵. شبکه‌های عصبی بازپراکنده^۹: بر اساس همان اصول شبکه‌های کانولوشنی عمل می‌کنند، با این تفاوت که عملیات به صورت برعکس اجرا می‌شود. این کاربرد خاص از هوش مصنوعی به هدف شناسایی سیگنال‌ها یا ویژگی‌های از دست رفته می‌پردازد که ممکن است در طول اجرای وظیفه اختصاص داده شده به شبکه عصبی کانولوشنی به عنوان غیرمهم شناخته شده باشند.

۶. شبکه‌های مولد مقابله‌ای^{۱۰}: یک راهکار مدل‌سازی تولیدی هستند که از شبکه‌های عصبی کانولوشنی و سایر امکانات یادگیری عمیق برای اتوماسیون کشف الگوها در داده‌ها استفاده می‌کنند. مدل‌سازی تولیدی از یادگیری بدون نظارت استفاده می‌کند تا نتایج معقولی از یک مجموعه داده اصلی بسازد.

هر نوع شبکه عصبی مزایا و معایب خود را دارد و انتخاب بین آنها به وظیفه خاص در دست استفاده بستگی دارد.

1. Artificial neural networks (ANNs)
2. Warren McCulloch
3. Walter Pitts
4. Frank Rosenblatt
5. Feedforward Neural Networks


6. Convolutional neural network (CNNs)
7. Modular Neural Networks
8. Recurrent Neural Network (RNN)
9. Deconvolutional Neural Networks
10. Generative Adversarial Networks

ورودی اعمال می‌کند. هر فیلتر ویژگی‌های خاصی از ورودی را فعال می‌کند، مانند لبه‌ها یا بافت‌ها، در مکان‌های فضایی مختلف. خروجی این لایه یک مجموعه از نقشه‌های ویژگی است.

۲. لایه استخراج^۲: پس از لایه کانولوشنی، لایه استخراج اندازه فضای نمایش را کاهش می‌دهد، تعداد پارامترها در شبکه را کاهش می‌دهد. این لایه همچنین در ایجاد تحمل به تغییرات مقیاس و جهت مشابهی برای ویژگی‌ها کمک می‌کند.

۳. لایه تابع فعال‌سازی^۳: تابع فعال‌سازی یک فعال‌سازی غیرخطی اعمال می‌کند که غیرخطیت را به سیستم می‌آورد و به شبکه این امکان را می‌دهد که مسائل غیرخطی را حل کند. تابع واحد یک‌سوسوده‌ی خطی^۴ به عنوان یک تابع فعال‌سازی رایج است زیرا در حل مشکل کاهش گرادیان کمک می‌کند و امکان یادگیری سریع‌تر و بهتر را فراهم می‌کند.

۴. لایه کاملاً متصل: در انتها، شبکه‌های عصبی کانولوشنی یک یا چند لایه کاملاً متصل دارند. نورون‌های لایه کاملاً متصل، همانند شبکه‌های عصبی معمولی، اتصالات کاملی به همه فعال‌سازی‌های لایه قبلی دارند. این لایه به طور اساسی یک حجم ورودی را (هرچه که خروجی از لایه‌های کانولوشنی یا استخراج باشد) دریافت می‌کند و یک بردار- N بعدی را خروجی می‌دهد که N تعداد کلاس‌هاست که برنامه برای شناسایی آنها طراحی شده است (شکل ۳).




شکل ۲. شبکه عصبی مصنوعی (منبع:
[https://rishabh27sharma.medium.com/neural-networks-\(e22cc32fbb45](https://rishabh27sharma.medium.com/neural-networks-(e22cc32fbb45))

ب) شبکه‌ی عصبی پیچشی: شبکه‌های عصبی کانولوشنی یک نوع ویژه از مدل‌های شبکه عصبی هستند که اصولاً برای پردازش داده‌هایی با ساختار شبکه‌ای طراحی شده‌اند (شکل ۲). در این مدل از فرایندهای بیولوژیکی در مغز انسان الهام گرفته‌اند، به خصوص از نحوه پردازش اطلاعات در قشر بصری مغز. آنها یکی از پایه‌های زیرمجموعه یادگیری عمیق از یادگیری ماشین هستند و به دلیل کارایی بالای خود در تشخیص الگوها و اشیاء در تصاویر و ویدئوها، زمینه بینایی کامپیوتر را ایجاد کرده‌اند.

شبکه‌های عصبی کانولوشنی از چند لایه تشکیل شده‌اند، هرکدام وظایف مختلفی را انجام می‌دهند:

۱. لایه کانولوشنی^۱: این لایه، سازه اصلی یک است. لایه کانولوشنی یک مجموعه از فیلترهای قابل یادگیری را بر روی



شکل ۳. شماتیک شبکه‌ی عصبی پیچشی
 (منبع: <https://www.geeksforgeeks.org/introduction-convolution-neural-network>)

1. Convolutional Layer
 2. Pooling

3. Activation Functions
 4. ReLU / Rectified Linear Unit

منحصر به فرد هستند که شامل چندین جزء کلیدی است (شکل ۴):

۱. حافظه سلول^۴: این بخش "حافظه" از شبکه عصبی حافظه کوتاه مدت ماندگار است. این در امتداد تمام بلوک‌های لایه شبکه عصبی حافظه کوتاه مدت ماندگار اجرا می‌شود و اطلاعات را از گام‌های زمانی اولیه به گام‌های بعدی منتقل می‌کند. همچنین می‌تواند اطلاعات را از طریق دروازه‌ها حذف یا اضافه کند.

۲. دروازه‌ها^۵: این شبکه‌ها دارای سه نوع دروازه هستند: دروازه فراموشی، دروازه ورودی و دروازه خروجی. این دروازه‌ها جریان اطلاعات ورودی و خروجی از حافظه را کنترل می‌کنند. آنها از توابع فعال‌سازی سیگموئید استفاده می‌کنند تا تصمیم بگیرند کدام اطلاعات را اجازه عبور دهند (ارزش‌های نزدیک به ۱) یا مسدود کنند (ارزش‌های نزدیک به صفر).

۳. دروازه فراموشی^۶: این دروازه تصمیم می‌گیرد کدام اطلاعات باید حذف یا نگه داشته شود. به ورودی فعلی و وضعیت پنهان قبلی نگاه می‌کند و برای هر عدد در حالت سلولی، یک عدد بین ۰ و ۱ را خروجی می‌دهد.

۴. دروازه ورودی^۷: دروازه ورودی حافظه سلول را با اطلاعات جدید به‌روز می‌کند. این دارای دو بخش است: یک لایه سیگموئید که تصمیم می‌گیرد کدام ارزش‌ها را به‌روز کند و یک لایه تابع تانژانت هایپربولیک^۸ که ارزش‌های کاندید جدیدی ایجاد می‌کند که می‌توانند به حالت اضافه شوند.

۵. دروازه خروجی^۹: دروازه خروجی تصمیم می‌گیرد که وضعیت پنهان بعدی چه باشد. وضعیت پنهان حاوی اطلاعاتی در مورد ورودی‌های گذشته است. دروازه خروجی به ورودی فعلی و حالت جدید سلول برای تعیین خروجی خود نگاه می‌کند.


هرچند که شبکه‌های عصبی کانولوشنی به طور قابل توجهی زمینه بینایی کامپیوتر را پیشبرد داده‌اند، اما با چالش‌هایی همراه هستند. آموزش شبکه‌های عصبی کانولوشنی نیاز به حجم زیادی از داده‌های برچسب خورده، قدرت محاسباتی قابل توجه و گاهی ممکن است به مدل‌هایی منجر شود که به دلیل پیچیدگی و کمبود قابل فهم برای توضیح، به عنوان "جعبه‌های سیاه" در نظر گرفته می‌شوند. تحقیقات در حال انجام در این حوزه با هدف حل این چالش‌ها صورت می‌گیرد تا شبکه‌های عصبی کانولوشنی را کارآمدتر، قابل تفسیرتر و قابل یادگیری از داده‌های کمتر کند. در نتیجه، شبکه‌های عصبی کانولوشنی ابزاری قدرتمند در ابزارهای هوش مصنوعی و یادگیری ماشین هستند، به ویژه برای وظایف مرتبط با پردازش تصویر و ویدئو. قابلیت آنها برای یادگیری به طور خودکار و تطبیقی از سلسله مراتب فضایی از ویژگی‌ها باعث می‌شود که برای بسیاری از وظایف در حوزه بینایی کامپیوتر باشند و پیشرفت‌های به‌روز در حال ادامه است که دامنه کاربرد آنها را در حوزه‌های مختلف گسترش می‌دهد.

ج) شبکه عصبی حافظه کوتاه مدت ماندگار^۱: شبکه‌های حافظه کوتاه مدت ماندگار، به طور رایج با نام LSTMs شناخته می‌شوند، نوع خاصی از شبکه‌های عصبی بازگشتی هستند که قادر به یادگیری وابستگی‌های بلند مدت هستند. این شبکه‌ها توسط هوخ‌رایتر^۲ و شمیدهور^۳ در سال ۱۹۹۷ معرفی شدند و از آن زمان به دلیل کارایی آنها در برنامه‌های مختلف، تصحیح و محبوبیت یافته‌اند. این شبکه‌ها اصطلاحاً برای یادگیری، پردازش و دسته‌بندی داده‌های توالی استفاده می‌شوند، زیرا این شبکه‌ها می‌توانند وابستگی‌های بلندمدت بین گام‌های زمانی را یاد بگیرند. آنها به ویژه در زمینه‌های تحلیل احساسات، مدل‌سازی زبان، تشخیص گفتار و تحلیل ویدئویی موثر هستند^۴.

شبکه‌های حافظه کوتاه مدت ماندگار دارای یک معماری

1. Long Short-Term Memory (LSTM)
2. Sepp Hochreiter
3. Jurgen Schmidhuber
4. Cell State
5. Gates

6. Forget Gate
7. Input Gate
8. Tanh | Hyperbolic Tangent
9. Output Gate



شکل ۴. شماتیک شبکه عصبی حافظه کوتاه مدت ماندگار

(منبع: <https://link.springer.com/article/10.1007/s10462-020-09838-1>)

مطرح می‌کنند (۱) پیش‌بینی شاخص قیمت سهام با رویکرد روشهای کلاسیک؛ (۲) رویکرد هوش مصنوعی؛ (۳) رویکرد ترکیبی. در همین راستا آن‌ها ابتدا ارزیابی عملکرد روشهای کلاسیک از قبیل روشهای هموارسازی نمایی، تحلیل روند، ARIMA و هوش مصنوعی از قبیل شبکه‌های عصبی و شبکه‌های عصبی فازی را مورد بررسی قرار داده، سپس سناریو سوم، یعنی طراحی مدل ترکیبی از ARIMA، شبکه‌های عصبی و شبکه‌های عصبی فازی را مورد بررسی قرار دادند. نتایج تحقیق بیانگر آن است که توانایی مدل ترکیبی نسبت به تمامی روشهای هوش مصنوعی و کلاسیک بالاتر است. حیدری و امیری (۱۴۰۱) قدرت مدل‌های مختلف مبتنی بر یادگیری ماشین، در پیش‌بینی روند قیمت سهام در بورس اوراق بهادار تهران را مورد بررسی قرار دادند. نتایج تحقیق آن‌ها نشان داد که مدل‌های مبتنی بر یادگیری عمیق نسبت به سایر مدل‌ها عملکرد بهتری از خود نشان می‌دهند و در پیش‌بینی روند کوتاه‌مدت قیمت سهام، از دقتی حدود ۷۰ تا درصد برخوردارند. همچنین، مدل‌های یادگیری کم‌عمق دقت بالاتری داشتند. به‌طور کلی، بیشتر مدل‌ها در پیش‌بینی روندهای منفی سهام، عملکرد بهتری نشان می‌دهند. عامری و طیبی (۱۴۰۴) در پژوهشی با عنوان «بررسی عملکرد روش شبکه عصبی بازگشتی (RNN) حافظه طولانی کوتاه مدت (LSTM) در پیش‌بینی قیمت سهام» به پیش‌بینی بازدهی قیمت سهام در

شبکه‌های عصبی حافظه کوتاه مدت ماندگار مناسب برای وظایف پیش‌بینی دنباله و در ثبت وابستگی‌های بلندمدت عالی عمل می‌کنند. کاربردهای آنها در وظایف مربوط به دنباله‌ها و سری‌ها گسترده است. آنها به خصوص در زمینه‌های ترجمه ماشینی، تشخیص گفتار، تحلیل احساسات، مدل‌سازی زبان، و تحلیل ویدئویی بسیار مؤثر هستند.

پیشینه تحقیق

فقیهی‌نژاد و مینایی (۱۳۹۷) برای افزایش دقت پیش‌بینی قیمت سهام از مدلی بر مبنای الگوریتم‌های یادگیری جمعی با مدل‌های پایه شبکه‌های عصبی استفاده کردند. آن‌ها برای در نظر گرفتن جهت تغییر قیمت در پیش‌بینی، ساختار دومرحله‌ای را بکار گرفتند. در مرحله نخست، جهت بعدی حرکت قیمت سهام (افزایش یا کاهش) پیش‌بینی شده و از آن برای پیش‌بینی قیمت در مرحله دوم استفاده شده است. نتایج معیارهای ارزیابی بر اساس شبکه‌های عصبی مصنوعی روی داده‌های واقعی قیمت سهام نشان داد که مدل پیشنهاد شده در مقایسه با سایر روش‌ها، با دقت بیشتری می‌تواند بر نوسان‌های بازار غلبه کرده و به‌عنوان روش قابل اطمینان و عملی در بازارهای سهام به‌کار گرفته شود. عادل آذر و همکاران (۱۴۰۰) در تحقیقی با عنوان «مقایسه روشهای کلاسیک و هوش مصنوعی در پیش‌بینی شاخص قیمت سهام و طراحی مدل ترکیبی» سه ۸۰ رویکرد را

بورس اوراق بهادار تهران با استفاده از شبکه عصبی بازگشتی حافظه طولانی کوتاه مدت (LSTM) پرداختند. در این تحقیق میانگین و انحراف معیار خطای پیش بینی مدل شبکه عصبی بازگشتی (LSTM) معناداری آماری مدل مذکور را نشان می دهد.

کاوستوبه خاره^۱ و همکاران (۲۰۱۷) طی مقاله تحت عنوان "پیش بینی کوتاه مدت قیمت سهام با استفاده از یادگیری عمیق" با استفاده از داده های یک ساله ۱۰ شرکت از بورس اوراق بهادار نیویورک که بصورت دقیقه ای (تایم فریم یک دقیقه) انتخاب شده و سپس نرمال سازی انجام شده است تا داده ها بین صفر و یک قرار بگیرند. در این مقاله از دو نوع شبکه عصبی استفاده شده است یک شبکه عصبی پیش خور با عنوان شبکه ای عصبی چند لایه پرسپترون و یک شبکه عصبی بازگشتی با عنوان شبکه عصبی کوتاه مدت ماندگار. برای مقایسه این دو مدل از معیار خطای میانگین مربعات ریشه استفاده شده است و نتایج نشان می دهد که مدل شبکه ای عصبی چند لایه پرسپترون عملکرد بهتری داشته است. چه یو لی^۲ و همکاران (۲۰۱۷) طی مقاله ای تحت عنوان «پیش بینی قیمت سهام با اخبار مالی مبتنی بر شبکه های عصبی پیچشی بازگشتی» از ترکیب یک شبکه عصبی پیچشی و یک شبکه عصبی کوتاه مدت ماندگار و الگوریتم تبدیل کلمه به بردار استفاده می کنند، همچنین داده های ورودی قیمت ها تاریخی و عناوین اخبار آن سهم می باشد، نتایج بدست آمده نشان می دهد که مدل ترکیبی از مدل شبکه ای عصبی کوتاه مدت ماندگار عملکرد بهتری دارد. هیرانشا^۳ و همکاران (۲۰۱۸) طی مقاله ای تحت عنوان «پیش بینی بازار سهام هند با استفاده از مدل های یادگیری عمیق» با استفاده از چهار نوع معماری یادگیری عمیق یعنی MLP، RNN، LSTM، CNN نسبت به پیش بینی قیمت سهام از دو بازار مختلف هند و آمریکا اقدام می کنند، به گونه ای که مدل ها بر اساس سهام

شرکتی از هند آموزش داده می شود و پنج شرکت مختلف از دو بازار هند و آمریکا پیش بینی می شود. و نتایج نشان می دهد که مدل CNN از سایر مدل ها عملکرد بهتری در این روش داشته است. ژیان کائو^۴ و همکاران (۲۰۱۹) طی مقاله ای تحت عنوان «مدل پیش بینی سری زمانی مالی بر اساس LSTM-CEEMDAN»^۵ بر روی چهار شاخص DAX، HSI، S&P500 و SSE بوده و از قیمت بسته شدن روزانه برای پیش بینی استفاده شده است. نتایج این مدل ترکیبی نشان می دهد که خطای بدست آمده از این مدل براساس توابع MAE، RMSE، MAPE، نسبت به مدل های LSTM، SVM، CEEMDAN-SVM، CEEMDAN-MLP، CEEMDAN-MLP عدد کمتری را نشان می دهد. همچنین این مدل قابلیت بهینه تر شدن را دارد چرا که برای ورودی فقط از قیمت بسته شدن استفاده شده است در حالیکه می توان تعداد ورودی ها را افزایش داد و از بالاترین قیمت و پایین ترین قیمت و حجم معاملات و سایر ویژگی های قیمت استفاده کرد. سیدرا مهتاب^۶ و همکاران (۲۰۲۱) طی مقاله ای با عنوان «پیش بینی قیمت سهام با استفاده از یادگیری ماشین و مدل های یادگیری عمیق مبتنی بر شبکه عصبی حافظه کوتاه مدت ماندگار» برای هدف مطالعه این پژوهش، از مقادیر شاخص NIFTY 50 بورس ملی هند^۷ در دوره زمانی ۲۹ دسامبر ۲۰۱۴ تا ۳۱ ژوئیه ۲۰۲۰ استفاده شده است. چارچوب پیش بینی در این پژوهش ساخت چهار مدل رگرسیون مبتنی بر یادگیری عمیق با استفاده از شبکه های حافظه بلندمدت و کوتاه مدت با رویکرد جدید روش اعتبارسنجی «پیش رونده»^۸ می باشد. از قدرت مدل های رگرسیون شبکه عصبی حافظه کوتاه مدت ماندگار در پیش بینی مقادیر قیمت باز شدن NIFTY 50 در آینده با استفاده از چهار مدل مختلف استفاده می کنیم که در معماری و ساختار داده های ورودی متفاوت هستند. نتایج به وضوح نشان می دهد که مدل تک متغیره مبتنی بر شبکه عصبی حافظه کوتاه مدت ماندگار که

1. Kaustubh Khare
2. Che -Yu. Lee
3. Hiransha
4. Jian Cao

5. Complete ensemble EMD with adaptive noise (CEEMDAN)
6. Sidra Mehtab
7. NSE
8. walk-forward validation

از داده‌های یک هفته قبل به عنوان ورودی برای پیش‌بینی ارزش قیمت باز شدن هفته آینده سری زمانی NIFTY 50 استفاده می‌کند دقیق‌ترین مدل است. ژائو و همکاران (۲۰۲۱) طی مقاله با عنوان «یک مدل ترکیبی ادغام یادگیری عمیق با تحلیل احساسات سرمایه گذار برای پیش بینی قیمت سهام» یک مدل ترکیبی ارائه می‌کنند که رویکرد یادگیری عمیق را با یک مدل تحلیل احساسات برای پیش‌بینی قیمت سهام ترکیب می‌کند. از یک مدل شبکه عصبی پیچشی برای طبقه بندی احساسات پنهان سرمایه گذاران استفاده شده است که از یک انجمن بزرگ سهام استخراج می‌شود. سپس یک مدل تحقیقاتی ترکیبی را با استفاده از رویکرد شبکه عصبی حافظه کوتاه مدت ماندگار برای تجزیه و تحلیل شاخص‌های فنی از بازار سهام و نتایج تحلیل احساسات ارائه شده است. علاوه بر این کار، آزمایش‌های واقعی را از شش صنعت کلیدی در سه بازه زمانی در بورس اوراق بهادار شانگهای (SSE) انجام داده است تا اثربخشی و کاربرد مدل پیشنهادی را تأیید کند. نتایج آزمایش نشان می‌دهد که مدل پیشنهادی نسبت به طبقه‌بندی‌کننده‌های پایه در طبقه‌بندی احساسات سرمایه‌گذار به عملکرد بهتری دست یافته است و این رویکرد ترکیبی در پیش‌بینی قیمت سهام در مقایسه با مدل واحد و مدل‌های بدون تحلیل احساسات عملکرد بهتری دارد. سونکاوده کارنج^۳ و همکاران (۲۰۲۳) به بررسی الگوریتم‌هایی مانند الگوریتم‌های یادگیری ماشینی تحت نظارت و بدون نظارت، الگوریتم‌های مجموعه، الگوریتم‌های تحلیل سری‌های زمانی و الگوریتم‌های یادگیری عمیق برای پیش‌بینی قیمت سهام و حل مسائل طبقه‌بندی پرداختند. این تحقیق سه موضوع را مورد بررسی قرار داد (الف) توصیفی از یادگیری ماشین و مدل‌های یادگیری عمیق مورد استفاده در بخش مالی، (ب) چارچوبی کلی برای پیش‌بینی و طبقه‌بندی قیمت سهام و (ج) استفاده از یک مدل متشکل از جنگل تصمیم تصادفی، شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) و XG-Boost برای پیش‌بینی قیمت

سهام. نتایج این تحقیق نشان می‌دهد مدل‌های پیش‌بینی سهام باید با تنظیم فراپارامتر مناسب تقویت شوند تا بتوانند به عنوان مدل‌های پیش‌بینی دقیق قیمت سهام عمل کنند. معامله‌گران و مشاوران سرمایه‌گذاری می‌توانند از یادگیری ماشین و مدل‌های یادگیری عمیق به عنوان شاخص‌های تأیید اضافی برای حمایت از تصمیم‌های خود استفاده کنند، و تصمیم‌ها نباید تنها بر روش‌های پیش‌بینی قیمت مبتنی بر هوش مصنوعی متکی باشند. گوپتا و جیسوال^۴ (۲۰۲۴) با استفاده از بسیاری از الگوریتم‌های یادگیری عمیق، پیش‌بینی قیمت سهام را مورد بررسی قرار دادند و برای این کار از داده‌های شاخص S&P 500 استفاده کردند. به همین منظور در این تحقیق برای دستیابی به نتایج از مدل آماری میانگین متحرک و ARIMA و از مدل‌های پیش‌بینی LSTM، RNN، CNN و FULL CNN که مدل‌های یادگیری عمیق هستند، استفاده شده است. نتایج نشان می‌دهد که استفاده از این مدل‌ها می‌تواند به سرمایه‌گذاران در پیش‌بینی قیمت‌ها و روند آتی بازار سرمایه کمک کند. موحیت بنیوال^۴ و همکاران (۲۰۲۴) به طور گسترده‌ای توانایی مدل‌های یادگیری عمیق را برای پیش‌بینی قیمت‌های روزانه شاخص‌های سهام جهانی در بلندمدت تا یک سال مورد بررسی قرار داد. عملکرد شش مدل، از جمله شبکه عصبی عمیق (DNN)، شبکه عصبی بازگشتی (RNN)، شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM)، حافظه کوتاه مدت دو وجهی (Bi-LSTM)، شبکه عصبی بازگشتی GRU و شبکه عصبی کانولوشنال (CNN)، با استفاده از ریشه میانگین مربعات خطا (RMSE) و میانگین درصد مطلق خطا (MAPE) مورد مقایسه قرار گرفت. این مدل‌ها قیمت‌های روزانه بلندمدت پنج شاخص سهام جهانی یعنی نیفتی، میانگین صنعتی داو جونز (DJIA)، شاخص عملکرد دکس، نیکی ۲۲۵ و شاخص ترکیبی بورس شانگهای را مورد پیش‌بینی قرار دادند. نتایج تحقیق آن‌ها برتری شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) را برای پیش‌بینی قیمت‌های روزانه بلندمدت

1. Zhao Wu
2. Sonkavde Gaurang

3. Gupta and Jaiswal
4. Mohit Beniwal

تأیید می‌کند. طبق نتایج تحقیق استفاده از مدل حافظه کوتاه مدت دو وجهی (Bi-LSTM) نتایج حاصل از مدل شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) را بهبود نمی‌بخشد اما بهتر از سایر الگوریتم‌ها عمل می‌کند. شبکه عصبی کانولوشنال (CNN) بیش از حد داده‌های آموزش (Train) را تطبیق می‌دهد و پیش بینی ضعیفی از قیمت سهام بلندمدت شاخص‌های جهانی بر روی داده‌های آزمون (Test) انجام می‌دهد. نتایج این تحقیق پتانسیل مدل‌های یادگیری عمیق را برای پیش‌بینی بلندمدت قیمت سهام نشان می‌دهد و بینش‌های ارزشمندی را برای سرمایه‌گذاران ارائه می‌دهد.

روش تحقیق

هدف اصلی این پژوهش پیش‌بینی قیمت سهام با استفاده از دو نوع شبکه عصبی در بازار سرمایه است. این مدل‌ها را از منظر دقت پیش‌بینی کنندگی به طور مطلق و نسبی بررسی می‌کنیم.

جامعه آماری این پژوهش بورس اوراق بهادار تهران می‌باشد. حجم نمونه آماری این پژوهش داده‌های سه نماد بورس اوراق بهادار تهران به شرح ایران خودرو، البرز دارو و توسعه معادن روی ایران می‌باشد. در این پژوهش از هشت ویژگی قیمت در چارچوب زمانی روزانه از تاریخ ۱۳۸۰ تا تاریخ ۱۴۰۰ استفاده می‌شود که شامل بالاترین قیمت، پایین‌ترین قیمت، قیمت بسته شدن (آخرین معامله)، قیمت باز شدن (اولین معامله)، ارزش معاملات، حجم معاملات، اختلاف قیمت بسته شدن دو روز متوالی، درصد تغییرات قیمت بسته شدن دو روز متوالی. نمونه‌گیری به صورت غیر تصادفی بوده است. تعداد زیاد داده‌ها نیز به دلیل نیاز مدل‌های یادگیری عمیق به تعداد داده‌های زیاد و عدم وجود شکاف قیمتی و زمانی هم به دلیل پیوستگی در داده‌ها در نظر گرفته شده است. اطلاعات و داده‌های مربوط به پژوهش از طریق سایت ره‌آورد نوین بدست آمده است.

فرآیند انجام پژوهش بدین صورت است که در مرحله اول بعد از ورود داده‌ها، تغییر مقیاس داده‌ها است که می‌توان به دو روش نرمالسازی و استاندارد سازی انجام داد که در این پژوهش از روش استاندارد سازی استفاده شده است. علت استفاده از این روش وجود ویژگی‌هایی با واحدهای غیر یکسان می‌باشد. روش نرمال سازی^۱: مقیاس‌بندی Min-Max یا Min-Max Scaler یکی از روش‌های رایج در نرمال‌سازی داده‌ها است که به منظور تغییر مقیاس داده‌ها به بازه‌ای مشخص میان دو مقدار حداقل و حداکثر انجام می‌شود. این روش باعث می‌شود تمام داده‌ها به بازه‌ای مشخصی مثل [۰، ۱] تغییر مقیاس یابند. روش استاندارد سازی^۲: استاندارد سازی یکی دیگر از روش‌های نرمال‌سازی داده‌هاست که به منظور تبدیل داده‌ها به یک توزیع با میانگین صفر و واریانس یک انجام می‌شود. در این روش، از میانگین و واریانس داده‌ها برای تغییر مقیاس و تبدیل واحدهای داده‌ها استفاده می‌شود. این کار به مدل‌های یادگیری ماشینی کمک می‌کند که بهتر و با دقت‌تر با داده‌ها برخورد کنند.

مرحله دوم این است که داده را به دو دسته آموزش^۳ و آزمون^۴ تقسیم کنیم. در این پژوهش در هر سه مدل، ۸۰ درصد داده را به عنوان داده‌های آموزش و ۲۰ درصد داده‌ها را به عنوان داده‌های آزمون فرض می‌کنیم. به علت محدود تعداد داده‌ها، از داده‌های آزمون، در ارزیابی عملکرد مدل نیز استفاده شده است. مرحله سوم، تبدیل داده‌های سری زمانی به فرمت نظارت شده است. تبدیل داده‌های سری زمانی به فرمت نظارت شده^۵، یک مرحله مهم برای استفاده از مدل‌های رگرسیونی در پیش‌بینی و تحلیل داده‌های سری زمانی است. در این فرمت، داده‌های سری زمانی به صورت جفت‌های ورودی و خروجی مرتبط تبدیل می‌شوند. به عبارت دیگر، از نمونه‌های گذشته برای پیش‌بینی مقدار در زمان آینده استفاده می‌شود. در این پژوهش برای تبدیل داده‌ها از سری زمانی به داده‌های نظارت شده از دستور زیر استفاده می‌کنیم. این کار معمولاً با استفاده از پنجره‌های زمانی ویژگی‌های قبلی به عنوان ورودی و مقدار

1. MinMaxScaler
2. Standardization
3. Train

4. Test
5. Supervised

تغییر می‌کند. خطای میانگین مطلق به سادگی قابل تفسیر است (رابطه ۱).

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - ty_i| \quad (۱)$$

ریشه میانگین مربعات خطا نیز مانند خطای میانگین مطلق، یک معیار اندازه‌گیری می‌باشد که در زمینه‌های مختلف از جمله آمار و یادگیری ماشین، برای اندازه‌گیری میزان تفاوت بین مقادیر پیش‌بینی شده و مقادیر واقعی یک متغیر استفاده می‌شود. این معیار مختصراً ریشه میانگین مربعات خطا نامیده می‌شود. به عنوان معیاری که تفاوت‌ها را به صورت مربعی محاسبه می‌کند، ریشه میانگین مربعات خطا به خطاهای بزرگتر و کوچکتر اهمیت می‌دهد. این معنایی از دقت در پیش‌بینی دارد که میزان تفاوت‌ها، حتی اگر کوچک باشند، در نهایت تأثیر خود را بر نتایج دارند. در مواجهه با خطاهای بزرگتر، ریشه میانگین مربعات خطا اهمیت بیشتری از خطای میانگین مطلق به آنها اختصاص می‌دهد (رابطه ۲).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (۲)$$

ضریب تعیین، معیاری است که میزان تفسیر متغیر وابسته توسط متغیرهای مستقل در یک مدل را اندازه‌گیری می‌کند. این معیار معمولاً در آمار و یادگیری ماشین استفاده می‌شود تا نشان دهد که مدل چه مقدار از تغییرات متغیر وابسته را توسط متغیرهای مستقل توجیه می‌کند. ضریب تعیین معادل میانگین مربعات ضریب همبستگی بین متغیر وابسته و متغیرهای مستقل است. در واقع، ضریب تعیین نشان می‌دهد که چه مقدار از تغییرات متغیر وابسته توسط تغییرات متغیرهای مستقل توجیه می‌شود. مقدار ضریب تعیین بین ۰ تا ۱ قرار می‌گیرد، که ۰ به معنای عدم توجیه تغییرات متغیر وابسته توسط متغیرهای مستقل است و ۱ به معنای توجیه کامل تغییرات است. مقدار ضریب تعیین به شما ایده می‌دهد که مدل شما چه مقدار از تغییرات واقعی را توجیه می‌کند. اگر مقدار ضریب تعیین بالا

زمان بعدی به عنوان خروجی انجام می‌شود. ابتدا گام زمانی^۱ را مشخص می‌کنیم. گام زمانی مشخص می‌کند که برای پیش‌بینی مقدار برچسب گذاری از چند گام زمانی قبل استفاده کنیم. در اینجا از گام زمانی ۲۲ استفاده شده است که برابر یک ماه کاری می‌باشد. در ادامه ماتریس‌های x_{train} و y_{train} و x_{test} و y_{test} را تشکیل می‌دهیم. مرحله چهارم برازش و ارزیابی مدل است. برازش مدل^۲ یعنی تطابق مدل با داده‌های آموزشی. این تطابق می‌تواند به سه صورت مختلف اتفاق بیفتد: برازش خوب^۳، بیش برازش^۴ و کم برازش^۵. این سه وضعیت به کیفیت آموزش مدل نسبت به داده‌های آموزشی و داده‌های جدید اشاره دارند. در نهایت برای رفع بیش برازش از روش شبکه الاستیک^۶ استفاده شده است. این روش از ترکیب دو روش Lasso و Ridge بدست می‌آید. روش Lasso نسبت به داده‌های پرت حساسیت زیادی ندارد، و همچنین بعضی از وزن‌ها را به صفر کاهش می‌دهد ولی ممکن است که بعضی وزن‌ها همچنان بزرگ باقی بمانند، اما در مدل Ridge که نسبت به داده‌های پرت حساسیت بیشتری دارد، وزن‌ها را کوچک می‌کند ولی هیچگاه صفر نمی‌شوند. مقادیر لانداها بصورت تجربی و آزمون و خطا بدست آمده است (سیاستین و میرجلیلی، ۲۰۱۹).

ارزیابی پژوهش

برای ارزیابی و سنجش میزان خطا بین مقدار واقعی و مقدار پیش‌بینی شده از سه معیار خطای میانگین خطای مطلق^۷، ریشه میانگین مربعات خطا^۸ و ضریب تعیین^۹ استفاده شده است. خطای میانگین مطلق یک معیار اندازه‌گیری است که در زمینه‌های مختلف، به ویژه در آمار و یادگیری ماشین، برای اندازه‌گیری میزان تفاوت بین مقادیر پیش‌بینی شده و مقادیر واقعی یک متغیر استفاده می‌شود. خطای میانگین مطلق در مقابل خطاهای بزرگ و پرت حساسیت کمتری دارد. این به این معناست که اگر تعدادی از پیش‌بینی‌ها خطا داشته باشند، خطای میانگین مطلق کمتر تحت تأثیر قرار می‌گیرد و مقدار کمی

1. time_step
2. Model Fitting
3. Goodfit
4. Overfitting
5. Underfitting

6. Elastic Net
7. Mean absolute error
8. Root mean square error
9. R- squared

باشد، این نشان می‌دهد که مدل‌تان با داده‌ها به خوبی مطابقت دارد (رابطه ۳).

$$R^2 = 1 - \frac{(\sum_{i=1}^n (y_i - \hat{y}_i)^2)/n}{(\sum_{i=1}^n (y_i - \bar{y})^2)/n} \quad (3)$$


در جدول ۱ نتایج و عملکرد هر دو مدل در هر سه شرکت قابل مشاهده است. نتایج حاصل از معیارهای ارزیابی نشان می‌دهد که عملکرد مدل‌ها چگونه بوده است. نتایج نشان می‌دهد که مدل شبکه عصبی پیچشی توانایی پیش بینی با دقت خوبی را دارا می‌باشند. شبکه‌های عصبی بازگشتی از بهترین نوع شبکه‌ها برای پیش بینی قیمت هستند، اما نتایج نشان می‌دهد که شبکه عصبی پیچشی عملکرد بهتری از شبکه عصبی حافظه کوتاه مدت ماندگار داشته است.

یافته‌های پژوهش


جدول ۱. عملکرد مدل‌ها

نماد	مدل	R_square	MAE	RMSE
ایران خودرو	CNN	٪ ۹۶/۰۵	۱۵۲	۴۸۵
ایران خودرو	LSTM	٪ ۹۴/۱۰	۳۰۴	۵۹۲
البرز دارو	CNN	٪ ۹۷/۲۴	۶۹۶	۱۲۷۶
البرز دارو	LSTM	٪ ۶۳/۸۰	۱۶۹۴	۳۳۸۱
توسعه معادن روی	CNN	٪ ۹۷	۱۴۴۷	۲۶۰۴
توسعه معادن روی	LSTM	٪ ۷۹/۶۳	۲۹۰۳	۶۴۳۲


نتایج عملکرد مدل‌ها در شکل‌های ۵ تا ۱۰ قابل مشاهده است.




شکل ۵. نمودار شرکت ایران خودرو (مدل CNN)




شکل ۶. نمودار شرکت ایران خودرو (مدل LSTM)




شکل ۷. نمودار شرکت البرز دارو (مدل CNN)



شکل ۸. نمودار شرکت البرز دارو (مدل LSTM)



شکل ۹. نمودار شرکت توسعه معادن روی ایران (مدل CNN)



شکل ۱۰. نمودار شرکت توسعه معادن روی ایران (مدل LSTM)

میزان پیچیدگی مدل از نظر تعداد واحد و فیلتر و همچنین تعداد لایه و تعداد متغیرهای مستقل اشاره کرد.


بحث و نتیجه گیری

با توجه به بررسی ادبیات موضوع، شبکه‌های عصبی و یادگیری عمیق در پیش‌بینی قیمت سهام نقش بسیار مهمی ایفا می‌کنند. این تکنولوژی‌ها از تجزیه و تحلیل داده‌های مالی و بازار سهام بهره‌برداری می‌کنند تا به تصمیم‌گیری‌های بهتر و پیش‌بینی دقیق‌تری برای سرمایه‌گذاران کمک کنند.


با بررسی نتایج که در جدول ۱ و تصاویر ۵ تا ۱۰ گزارش شده است نشان می‌دهد که مدل شبکه عصبی حافظه کوتاه مدت ماندگار برعکس مدل شبکه عصبی پیچشی عملکرد قابل قبول ندارد. با توجه به این که این دو مدل در شرایط یکسان بررسی شده اند می‌توان نتیجه گرفت که مدل شبکه عصبی پیچشی با پیکربندی یکسانی که در این پژوهش انجام شده است عملکرد بهتری نسبت مدل شبکه عصبی حافظه کوتاه مدت ماندگار داشته است. البته عوامل بسیاری در دقت پیش بینی کنندگی مدل‌ها اثر گذار است که در اینجا می‌توان به

داده‌های سری زمانی به فرمت نظارت شده، یک مرحله مهم برای استفاده از مدل‌های رگرسیونی در پیش‌بینی و تحلیل داده‌های سری زمانی است. در این فرمت، داده‌های سری زمانی به صورت جفت‌های ورودی و خروجی مرتبط تبدیل می‌شوند. به عبارت دیگر، از نمونه‌های گذشته برای پیش‌بینی مقدار در زمان آینده استفاده می‌شود. و در نهایت در مرحله چهارم برازش و ارزیابی مدل انجام شد. برازش مدل به معنای تطابق مدل با داده‌های آموزشی است. این تطابق می‌تواند به سه صورت مختلف اتفاق بیافتد: برازش خوب، بیش برازش و کم برازش. همچنین در این پژوهش برای ارزیابی و سنجش میزان خطا بین مقدار واقعی و مقدار پیش‌بینی شده از سه معیار خطای میانگین خطای مطلق، ریشه میانگین مربعات خطا و ضریب تعیین استفاده شد. در شکل ۱۱ تا ۱۳ نتایج حاصل از این سه معیار برای دو روش پیش‌بینی CNN و LSTM برای سه سهم ایران خودرو، دارویی البرز و توسعه معادن روی نشان داده شده است.


همان طور که در این تحقیق بیان شد در این پژوهش از هشت ویژگی قیمت در چارچوب زمانی روزانه از تاریخ ۱۳۸۰ تا تاریخ ۱۴۰۰ استفاده شده است که شامل بالاترین قیمت، پایین‌ترین قیمت، قیمت بسته شدن (آخرین معامله)، قیمت باز شدن (اولین معامله)، ارزش معاملات، حجم معاملات، اختلاف قیمت بسته شدن دو روز متوالی، درصد تغییرات قیمت بسته شدن دو روز متوالی. نمونه‌گیری به صورت غیر تصادفی بوده است. وجود تعداد زیاد داده‌ها در این تحقیق به دلیل نیاز مدل‌های یادگیری عمیق به تعداد داده‌های زیاد و عدم وجود شکاف قیمتی و زمانی هم به دلیل پیوستگی در داده‌ها در نظر گرفته شده است. فرایند انجام پژوهش طی چهار مرحله انجام شد. در مرحله اول بعد از ورود داده‌ها، مقیاس داده‌ها با استفاده از روش استاندارد سازی تغییر داده شد و در مرحله دوم داده‌ها به دو دسته آموزش و آزمون تقسیم شدند. که در این پژوهش ۸۰ درصد داده به عنوان داده‌های آموزش و ۲۰ درصد داده‌ها به عنوان داده‌های آزمون مورد استفاده قرار گرفتند. در مرحله سوم داده‌های سری زمانی به فرمت نظارت شده تبدیل شدند. تبدیل



شکل ۱۱. ارزیابی و سنجش میزان خطا بین مقدار واقعی و مقدار پیش‌بینی شده با استفاده از ضریب تعیین (R_square)



شکل ۱۲. ارزیابی و سنجش میزان خطا بین مقدار واقعی و مقدار پیش‌بینی شده با استفاده از ریشه میانگین مربعات خطا (MAE)



شکل ۱۳. ارزیابی و سنجش میزان خطا بین مقدار واقعی و مقدار پیش‌بینی شده با استفاده از خطای میانگین خطای مطلق (RMSE)

(CNN) علاوه بر توان تبیین بیشتر قیمت سهام توانسته است خطای کمتری نسبت به شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) داشته باشد که این مورد به وضوح از طریق سه معیار در جداول ۱۱ تا ۱۳ قابل مشاهده است. نتایج مطالعات انجام شده در این حوزه نشان می‌دهد که شبکه‌های عصبی و یادگیری عمیق با تجزیه و تحلیل دقیق داده‌های

نتایج نشان می‌دهد که مدل شبکه عصبی پیچشی (CNN) توانایی پیش‌بینی با دقت خوبی را دارا می‌باشند. شبکه‌های عصبی بازگشتی از بهترین نوع شبکه‌ها برای پیش‌بینی قیمت هستند، اما نتایج نشان می‌دهد که شبکه عصبی پیچشی عملکرد بهتری از شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM) داشته است. شبکه عصبی پیچشی

سهام و طراحی مدل ترکیبی. پژوهش های مدیریت در ایران، ۱۰(۴)، ۱-۱۶.

حیدری زارع، بهزاد، و کردلویی، حمیدرضا. (۱۳۸۹). پیش بینی قیمت سهام با استفاده از شبکه عصبی مصنوعی. پژوهشگر (مدیریت) (Journal of Industrial Strategic Management)، ۷(۱۷)، صص ۴۹-۵۶.

حیدری، مهدی؛ امیری، حمیدرضا (۱۴۰۱). بررسی قدرت مدل های مبتنی بر هوش مصنوعی در پیش بینی روند قیمت سهام بورس اوراق بهادار تهران. تحقیقات مالی، ۲۴(۴)، ۶۰۲-۶۲۳.

روحی، ابوالفضل؛ رستگار سرحه، محمدعلی (۱۴۰۲). پیش بینی روند قیمت سهام با استفاده از ترکیب شبکه عصبی کانولوشن و شبکه عصبی حافظه کوتاه مدت در بازار بورس تهران. نوزدهمین کنفرانس ملی رویکردهای نوین در مدیریت، اقتصاد و حسابداری.

سعیدی اقدم، مهران و همکاران (۱۴۰۱). ارائه مدل پیش بینی قیمت سهام با استفاده از الگوریتم های یادگیری عمیق و کاربرد آن در قیمت گذاری سهام بانک های اسلامی. فصلنامه علمی اقتصاد و بانکداری اسلامی، زمستان ۱۴۰۱، صص ۱۱۷-۱۳۴.

شریف فر، امیر و همکاران (۱۴۰۰). ارزیابی و اعتبارسنجی معماری بهینه یادگیری عمیق در پیش بینی قیمت سهام (رویکرد الگوریتم حافظه کوتاه مدت ماندگار LSTM).

فصلنامه مهندسی مالی و مدیریت اوراق بهادار، شماره ۴۸. عامری شهرابی، حسین؛ طبیبی ثانی، احسان (۱۴۰۴). بررسی عملکرد روش شبکه عصبی بازگشتی (RNN) حافظه طولانی کوتاه مدت (LSTM) در پیش بینی قیمت سهام. دانش سرمایه گذاری، ۱۴(۵۵)، ۹۳-۱۱۷.

فقیهی نژاد، محمد تقی؛ مینایی، بهروز. (۱۳۹۷). پیش بینی رفتار بازار سهام بر اساس شبکه های عصبی مصنوعی با رویکرد یادگیری جمعی هوشمند. مدیریت صنعتی، ۱۰(۲)، ۳۱۵-۳۳۴.

تاریخی و شاخص های مالی، می توانند پیش بینی های دقیقی در مورد قیمت سهام ارائه دهند. این دقت بالا به سرمایه گذاران کمک می کند تا تصمیم گیری های بهتری برای سرمایه گذاری خود بگیرند. با توجه به اینکه پیش بینی و مدلسازی قیمت همواره امری پر چالش و جز جدایی ناپذیر تحلیل های سرمایه گذاران بوده، و از طرفی استفاده از شبکه های عصبی در امور مالی گسترشی روز افزون داشته است استفاده از مدل های مختلف شبکه ای عصبی می تواند باعث ایجاد مدل های قدرتمند از هر لحاظ در این زمینه شود.

با توجه به پیشرفت روز افزون مدل های یادگیری عمیق در پیش بینی داده های مختلف از جمله داده های مالی، تلاش کرده ایم در این پژوهش به بررسی برخی از مدل های یادگیری عمیق برای تخمین و پیش بینی در بورس اوراق بهادار تهران بپردازیم. با توجه به محدودیت ها و ویژگی های خاص بورس اوراق بهادار تهران، مانند دامنه نوسان، موجب ایجاد علاقه در محققان جهت بررسی و پیش بینی این بازار با استفاده از مدل های یادگیری ماشین و یادگیری عمیق می شود. نتایجی که یافته های این پژوهش نشان می دهد، این است که مدل های یادگیری عمیق در صورتی که در انتخاب ویژگی هایی (متغیرهای مستقل) که بتوانند بیشترین میزان معناداری را در تفسیر علل فراز و فرودهای قیمت را دوره های رونق و رکود بازار بیان کند، قابلیت و توانایی پیش بینی قیمت، با دقت قابل قبول دارا می باشند.

برای پژوهش های آینده می توان مدل ترکیبی حاصل از این دو مدل مورد استفاده در این پژوهش را مورد بررسی قرار داد. همچنین با توجه به اینکه در این پژوهش صرفاً از داده های گذشته نگر و فنی استفاده شده است می توان از داده های موثر دیگر بر بازار سرمایه مانند داده های بنیادی و کلان مانند نرخ اوراق منتشره در بازار بدهی و نرخ بهره سیاستی استفاده کرد.

منابع

آذر، عادل، افسر، امیر، احمدی، پرویز (۱۴۰۰). مقایسه روشهای کلاسیک و هوش مصنوعی در پیش بینی شاخص قیمت

- Mohit Beniwal, Archana Singh, Nand Kumar (2024). Forecasting multistep daily stock prices for long-term investment decisions: A study of deep learning models on global indices, *Engineering Applications of Artificial Intelligence*, Volume 129, 107617, ISSN 0952-1976,
- Sebastian Raschka and Vahid Mir Jalili (2019). *Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2*, 3rd Edition, Packt Publishing. SBN:978-1-78712-593-3.
- Sidra Mehtab, Jaydip Sen, Abhishek Dutta (2021). Stock Price Prediction Using Machine Learning and LSTM-Based Deep Learning Models. *TechRxiv*. August 05.
- Sonkavde, Gaurang, Deepak Sudhakar Dharrao, Anupkumar M. Bongale, Sarika T. Deokate, Deepak Doreswamy, and Subraya Krishna Bhat (2023). Forecasting Stock Market Prices Using Machine Learning and Deep Learning Models: A Systematic Review, Performance Analysis and Discussion of Implications, *International Journal of Financial Studies* 11, no. 3: 94.
- Wu, Zhao & Jing, Nan & Wang, Hefei. (2021). A Hybrid Model Integrating Deep Learning with Investor Sentiment Analysis for Stock Price Prediction. *Expert Systems with Applications*. 178. 115019. 10.1016/j.eswa.2021.115019.
- مرادی، مرتضی (۱۴۰۲). پیشبینی قیمت سهام با استفاده از شبکه عصبی بازگشتی، واحد بازگشتی دروازه ای و حافظه کوتاه مدت ماندگار: بررسی شرکت ایران خودرو. *نهمین کنفرانس بین المللی مهندسی صنایع و سیستم-ها، ایران، مشهد*.
- Cao, Jian & Li, Zhi & Li, Jian (2019). Financial time series forecasting model based on CEEMDAN and LSTM, *Physica A: Statistical Mechanics and its Applications*, Elsevier, vol. 519(C), pages 127-139.
- Che -Yu. Lee and V. -W. Soo, (2017). Predict Stock Price with Financial News Based on Recurrent Convolutional Neural Networks, *Conference on Technologies and Applications of Artificial Intelligence (TAAI)*, Taipei, Taiwan, pp. 160-165.
- Himanshu Gupta & Aditya Jaiswal, (2024). A Study on Stock Forecasting Using Deep Learning and Statistical Models, *Papers* 2402.06689, *arXiv.org*.
- Hiransha M, Gopalakrishnan E.A., Vijay Krishna Menon, Soman K.P. (2018). NSE Stock Market Prediction Using Deep-Learning Models, *Procedia Computer Science*, Volume 132, Pages 1351-1362.
- Khare, Kaustubh & Darekar, Omkar & Gupta, Prafull & Attar, Vahida. (2017). Short term stock price prediction using deep learning. 482-486.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

Forecasting stock prices in the capital market with an artificial intelligence approach

Asgar Noorbakhsh¹, Mostafa Shaygani²

1st Assistant Professor, Department of Financial Management, Faculty of Management and Accounting, Farabi Campus, University of Tehran, Qom, Iran
anoorbakhsh@ut.ac.ir

2nd Master of Financial Management, Faculty of Management and Accounting, Farabi Colleges of Tehran University, Qom, Iran
shaygani@ut.ac.ir

Abstract

The main objective of this research is to predict stock prices using two types of neural networks in the Tehran Stock Exchange. Python language in the VS Code editor has been used to conduct this research. The statistical population of this research is the Tehran Stock Exchange. The sample size of this research includes data from three symbols of the Tehran Stock Exchange, namely Iran Khodro, Alborz Darou, and Iran Zinc Mines Development. In this research, eight price features are used within the daily timeframe from 2001 to 2021, including the highest price, lowest price, closing price, opening price, transaction value, transaction volume, the difference in closing price between two consecutive days, and daily return. Three metrics of mean absolute error, root mean square error, and coefficient of determination have been used to evaluate the models' performance. The results indicate that the convolutional neural network model has the ability to predict with good accuracy. Recurrent neural networks are among the best types of networks for price prediction, but the results show that the convolutional neural network has performed better than the short-term memory neural network. The results suggest that deep learning models, when selecting features (independent variables) that can express the highest level of significance in interpreting the causes of price fluctuations during market booms and recessions, have the ability and capability to predict prices with acceptable accuracy.

Keywords: Artificial Neural Network, Short-Term persistent Memory, Convolutional Neural Network, Price Prediction.