



فصلنامه راهبرد مدیریت مالی

دانشگاه الزهرا

سال دهم، شماره سی و نهم، زمستان ۱۴۰۱

صفحات ۱۵۰-۱۲۵



### مقاله پژوهشی

ارزیابی روش ترکیبی PSO-BiLSTM برای پیش‌بینی قیمت سهام با استفاده از داده‌های سری زمانی قیمتی سهام (مطالعه موردی: سهام ارزشی بورس و فرابورس ایران)<sup>۱</sup>

جلیل وزیری کردستانی<sup>۲</sup>، داریوش فرید<sup>۳</sup>، مهدی ناظمی اردکانی<sup>۴</sup>، سید مجتبی حسینی بامکان<sup>۵</sup>

تاریخ پذیرش: ۱۴۰۱/۱۱/۰۸

تاریخ دریافت: ۱۴۰۱/۰۳/۲۴

### چکیده

در سال‌های اخیر با افزایش ضریب نفوذ بازار سرمایه، افراد بیشتری متمایل به سرمایه‌گذاری در بورس شده‌اند. پیش‌بینی دقیق قیمت سهام با کمترین خطا می‌تواند ریسک سرمایه‌گذاری را کاهش و بازده سرمایه‌گذاری را افزایش دهد. پیش‌بینی قیمت سهام به دلیل نوسانات غیرخطی اغلب به عنوان مسئله سری زمانی غیرخطی توصیف می‌شود که تحت تأثیر عوامل زیادی است. در این پژوهش، روش *BiLSTM* (*Bidirectional Long Short-Term Memory*) برای پیش‌بینی قیمت سهام ارزیابی می‌گردد. در این راستا، از چندین تکنیک یادگیری ماشین جهت پیش‌بینی قیمت سهام با استفاده از داده‌های سری زمانی قیمت‌های سهام استفاده می‌شود و نهایتاً دو روش یادگیری عمیق شامل الگوریتم شبکه عصبی خود بازگشتی (*Long Short-Term Memory*) و الگوریتم شبکه عصبی خود بازگشتی دوطرفه (*BiLSTM*) در این راستا پیاده‌سازی و نتایج آنها مقایسه می‌شوند. داده‌های سری زمانی مشخصه‌های قیمتی شامل قیمت باز، قیمت بسته، قیمت بالا و قیمت پایین برای سهام ارزشی شرکت‌های پذیرفته شده در بورس و فرابورس اوراق بهادار تهران از ابتدای سال ۱۳۹۲ تا پایان سال ۱۳۹۸، در جهت پیاده‌سازی روش‌های مذکور به عنوان مطالعه موردی استفاده می‌گردند. نتایج این پژوهش نشان داد که مدل ترکیبی *PSO-BiLSTM* در نظر گرفتن معیارهای ارزیابی *RMSE* و *R-Square* خطای کمتری در پیش‌بینی قیمت‌های سهام مورد مطالعه و عملکرد بهتری نسبت به الگوریتم‌های *CART*، *SVM*، *MLP*، *LSTM* و *BiLSTM* دارد.

**واژگان کلیدی:** پیش‌بینی قیمت، سری‌های زمانی، شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه، الگوریتم

بهینه‌سازی ازدحام ذرات، سهام ارزشی.

**طبقه‌بندی موضوعی:** C22، C45، G17

۱. کد DOI مقاله: 10.22051/JFM.2023.40712.2701

۲. دانشجوی دکتری، گروه مالی-مهندسی مالی، دانشگاه یزد، یزد، ایران. Email:j.vaziri.k@gmail.com

۳. دانشیار، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران. نویسنده مسئول. Email:Fareed@yazd.ac.ir

۴. استادیار، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران. Email: Nazemi@yazd.ac.ir

۵. استادیار، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران. Email:Smhosseini@yazd.ac.ir

## مقدمه

بازار سهام به عنوان مکانی برای جذب سرمایه از سرمایه‌گذاری‌های کوچک و سوق دادن آنها به سمت فعالیت‌های اقتصادی و بهره‌وری، نقش کلیدی در اقتصاد ایفا می‌کند. بنابراین حضور فعال در این بازار می‌تواند منجر به تخصیص بهینه سرمایه به فعالیت‌های دارای ارزش افزوده و در نتیجه افزایش رشد و شکوفایی اقتصادی شود. یکی از اهداف اصلی بازارهای مالی پیش‌بینی دقیق قیمت سهام در زمان مناسب به منظور خرید و یا فروش آنها در زمان دیگری در آینده برای به حداکثر رساندن سود است. در این شرایط، اصطلاح «قیمت هدف» به کار رفته در چنین بازارهایی به قیمتی اطلاق می‌شود که به درستی تخمین زده می‌شود و این امر بسیار پیچیده است زیرا عوامل متعددی بر قیمت سهام اثر می‌گذارند (ساده، احتشام و شیدایی، ۱۳۹۶).

پیش‌بینی سری‌های زمانی داده‌های مالی و به طور خاص قیمت سهام، یکی از سخت‌ترین مسائل برای پژوهشگران بوده است و نقش کلیدی در اتخاذ استراتژی‌های معاملاتی و شناسایی فرصت‌های خرید و فروش سهام ایفا می‌کند. موضوع پیش‌بینی قیمت سهام در مبانی نظری مالی یکی از توسعه یافته‌ترین مباحث است بطوریکه مدل‌های بسیار متنوع با ویژگی‌های خاص و متفاوت برای پیش‌بینی قیمت سهام طرح‌ریزی شده است. تحلیل و پیش‌بینی قیمت سهام در بازار با استفاده از روش‌های مختلف از جمله تحلیل‌های فنی<sup>۱</sup> و بنیادی<sup>۲</sup>، آنالیز رگرسیون<sup>۳</sup>، سری‌های زمانی<sup>۴</sup>، تئوری فازی<sup>۵</sup>، یادگیری ماشین<sup>۶</sup> و الگوریتم‌های مختلف صورت می‌گیرد (اوبرلچنر<sup>۷</sup>، ۲۰۰۱) تحلیل بنیادی طی فرآیندی، گزارش‌های مالی شرکت‌ها و اخبار موجود و داده‌های اقتصاد کلان را به منظور پیش‌بینی سود آینده و محاسبه قیمت منصفانه و منطقی برای سهام بررسی می‌کند (دچو<sup>۸</sup> و همکاران، ۲۰۰۱)، در حالیکه تحلیل تکنیکال (فنی) می‌تواند شامل طیف گسترده‌ای مدل‌ها و روش‌ها باشد از جمله: خرید و فروش سهام بر مبنای نمودارها شامل؛ بررسی نمودار قیمت سهام و ارسال سیگنال‌های خرید و فروش از طریق ترکیبی از نشانگرها و نوسانگرها (ادواردز<sup>۹</sup>، مگی<sup>۱۰</sup> و باستی<sup>۱۱</sup>، ۲۰۰۷)، تکنیک‌های آماری و یادگیری ماشین (رز<sup>۱۲</sup>، آگاروال<sup>۱۳</sup> و سستری<sup>۱۴</sup>).

1. Technical Analysis
2. Fundamental Analysis
3. Regression Analysis
4. Time Series
5. Fuzzy Theory
6. Machine Learning
7. Oberlechner
8. Dechow
9. Edwards
10. Magee
11. Bassetti
12. Rather
13. Agarwal
14. Sastry

۲۰۱۵) و الگوریتم‌های تکاملی (واسیلیادیس<sup>۱</sup>، ثومایدیس<sup>۲</sup> و دونیاس<sup>۳</sup>، ۲۰۱۱؛ آگیلار<sup>۴</sup> و والنزوئلا<sup>۵</sup>، ۲۰۱۹). تعیین قیمت سهام بر مبنای روند تاریخی می‌تواند بازده سهام مورد بررسی را در بازه زمانی مد نظر سرمایه‌گذار پیش‌بینی نماید و سهام‌ها با افزایش قیمت و بازدهی بیشتر را در یک بازه زمانی مشخص تخمین بزند. روش‌هایی که اغلب در این زمینه مورد استفاده قرار می‌گیرند، به مدلسازی رابطه بین رفتار تاریخی و حرکت آتی قیمت سهام می‌پردازند (کیم<sup>۶</sup> و هان<sup>۷</sup>، ۲۰۰۰). مدلسازی رفتار تاریخی و پیش‌بینی قیمت سهام و برخی دیگر از موضوعات چالش‌برانگیز در بازارهای مالی، نوع خاصی از سری‌های زمانی هستند.

از جنبه مفهومی، سری زمانی عبارت است از هر دنباله‌ای از اندازه‌گیری‌ها یا مشاهدات در فواصل منظم که به ترتیب زمانی در یک دوره زمانی خاص وجود دارند. تحلیل سری زمانی به طور عمده شامل تکنیک‌های آماری به منظور توصیف الگوهای داده‌ها است. در حوزه مالی، به واسطه ماهیت پیچیده سری‌های زمانی مربوطه، الگوها را نمی‌توان با روش‌های سنتی به درستی درک نمود زیرا این روش‌ها عمدتاً مبتنی بر تخمین پارامتر و رگرسیون خطی می‌باشند، در حالی که عمده سری‌های زمانی حوزه مالی تمایل به نمایش غیرخطی دارند (خاشعی<sup>۸</sup>، بیجاری<sup>۹</sup> و اردلی<sup>۱۰</sup>، ۲۰۱۲). یادگیری عمیق یک روش جدید است که می‌تواند در این زمینه مورد استفاده قرار گیرد. با توجه به پیشرفت‌های بی‌سابقه در یادگیری عمیق، بسیاری از زمینه‌های علمی از عملکرد دقیق بالای آن برای ایجاد راه حل‌های کارآمد برای انواع مختلف مشکلات و برای انجام عملیات پیش‌بینی و طبقه‌بندی بر اساس داده‌های آموزشی بسیار پیچیده استفاده می‌کنند (کلهر جی. دی<sup>۱۱</sup>، ۲۰۱۹). بنابراین، بررسی تکنیک‌های DNN در پیش‌بینی سری‌های زمانی داده‌های مالی مورد بررسی قرار می‌گیرند. تعدادی از پژوهش‌ها از تکنیک‌های یادگیری عمیق جهت پیش‌بینی سری‌های زمانی بهره برده‌اند. شبکه عصبی بازگشتی عمیق (RNN) یکی از تکنیک‌های پر کاربرد است (لیو<sup>۱۲</sup> و همکاران، ۲۰۲۰) که می‌تواند ورودی‌های داده قبلی را حین استفاده از داده‌های فعلی برای یادگیری وزن‌های شبکه به خاطر بسپارد. انواع مختلف RNN عمیق از جمله حافظه بلندمدت (LSTM)، به منظور بهبود توانایی شبکه RNN در حفظ حالت‌های قبلی شبکه و درک وابستگی‌های طولانی مدت ایجاد شده‌اند. LSTM اولیه برای گسترش وضعیت حافظه RNN ایجاد شد تا بتواند توالی‌های ورودی طولانی‌تر را بررسی کند (یو<sup>۱۳</sup> و

1. Vassiliadis
2. Thomaidis
3. Dounias
4. Aguilar
5. Valenzuela
6. Kim
7. Han
8. Khashei
9. Bijari
10. Ardali
11. Kelleher, J. D.
12. Liu
13. Yu

همکاران، ۲۰۱۹). شکل دیگری از LSTM, RNN دو جهته (iLSTMB) است که در آن توالی‌های ورودی قبلی و بعدی می‌توانند برای بهره‌برداری از تمام داده‌های ورودی به منظور تأمین بهترین عملکرد در فرآیند یادگیری استفاده شوند.

در این پژوهش، با هدف ارزیابی عملکرد روش PSO-BiLSTM، از چندین تکنیک یادگیری ماشین جهت پیش‌بینی قیمت سهام ارزشی با استفاده از داده‌های سری زمانی قیمت‌های سهام استفاده می‌گردد و نهایتاً دو روش یادگیری عمیق شامل LSTM و BiLSTM و همچنین، مدل ترکیبی PSO-BiLSTM. در این راستا، پیاده‌سازی و نتایج آنها مقایسه می‌شوند. داده‌های سری زمانی مشخصه‌های قیمتی شامل قیمت باز، قیمت بسته، قیمت بالا و قیمت پایین برای سهام ارزشی شرکت‌های بورس و فرابورس انتخاب شده از طریق فرآیند مندرج در شکل ۱، در جهت پیاده‌سازی روش‌های مذکور به عنوان مطالعه موردی استفاده می‌گردند. پیاده‌سازی روش BiLSTM و مدل ترکیبی PSO-BiLSTM به منظور پیش‌بینی قیمت سهام مورد مطالعه و مقایسه نتایج حاصله با نتایج حاصل از برخی دیگر از روش‌های پرکاربرد یادگیری ماشین از این جهت حائز اهمیت است که پیش‌بینی قیمت سهام پذیرش شده در بازار بورس ایران با استفاده از روش BiLSTM و ترکیب آن با الگوریتم بهینه‌سازی ازدحام ذرات تاکنون مورد ارزیابی قرار نگرفته است.



شکل ۱. فرایند انتخاب سهام ارزشی مورد مطالعه

ساختار ارائه مطالب در ادامه این پژوهش بدین شرح است که مبانی نظری شامل پیش‌بینی قیمت سهام، سری‌های زمانی، الگوریتم‌های یادگیری ماشین، روش یادگیری عمیق از جمله LSTM و BiLSTM و همچنین پیشینه پژوهش در بخش دوم ارائه می‌گردند، روش‌شناسی پژوهش شامل داده‌ها و چگونگی هم‌مقیاس نمودن آنها در بخش سوم مورد بحث قرار می‌گیرند، بخش ۴ به تبیین نتایج حاصل از پیاده‌سازی روش‌های مورد استفاده و تفسیر نتایج عددی می‌پردازد و نهایتاً مقایسه نتایج و بحث و نتیجه‌گیری در بخش ۵ ارائه می‌شوند.

## مبانی نظری و پیشینه پژوهش

### پیش‌بینی قیمت سهام

یکی از اهداف اصلی در بازارهای مالی، پیش‌بینی صحیح قیمت سهام در زمان مناسب است تا بتوان در زمان مناسب نسبت به خرید و فروش آنها اقدام کرد به گونه‌ای که حداکثر سود ممکن به دست آید. در چنین شرایطی، اصطلاحی که در بازارهای مالی از آن به عنوان قیمت هدف نام می‌برند، در واقع قیمتی است که باید درست پیش‌بینی شود (ژانگ<sup>۱</sup> و وو<sup>۲</sup>، ۲۰۰۹). امکان پیش‌بینی قیمت سهام، موضوعی است که به مدت بسیار زیادی مورد چالش بوده است. با این وجود در حال حاضر ابزارهای تحلیل بنیادی و تحلیل تکنیکال به عنوان روش‌های قابل اتکا باقی مانده و مورد استفاده قرار می‌گیرند و در سال‌های اخیر، روش‌های یادگیری ماشین نیز به منظور تحلیل سری‌های زمانی مالی به کار برده شده‌اند (جینگ<sup>۳</sup>، وو<sup>۴</sup> و وانگ<sup>۵</sup>، ۲۰۱۹).

قبل از ظهور الگوریتم‌های یادگیری ماشین مؤثر و کاربردی، پژوهشها معمولاً از روش‌های آماری و اقتصادسنجی به منظور ایجاد مدل‌های پیش‌بینی استفاده می‌کردند (نیلسن<sup>۶</sup>، ۲۰۱۹). مدل‌های اقتصادسنجی و آماری مرسوم نیاز به مدل‌های خطی دارند و از آنها نمی‌توان به منظور تحلیل و پیش‌بینی اطلاعات مالی از جمله قیمت سهام قبل از تبدیل مدل‌های غیرخطی به خطی استفاده کرد. با این وجود برخی از روش‌های آماری سنتی مانند رگرسیون خطی، میانگین متحرک و خودهمبسته<sup>۷</sup> به دلیل تفسیرپذیری، بیشتر در پیش‌بینی سری‌های زمانی داده‌های مالی مورد استفاده قرار گرفته‌اند. در این حوزه، مهم‌ترین بخش پیش‌بینی، تحلیل فنی است که با فرض حرکت قیمت سهام در آینده بر مبنای روندهای تاریخی صورت می‌گیرد (شینکوویچ<sup>۸</sup> و همکاران، ۲۰۱۷). جدا از روش‌های آماری، الگوریتم‌های یادگیری ماشین مانند بیز ساده<sup>۹</sup>، جنگل تصادفی<sup>۱۰</sup> و نزدیکترین k همسایه<sup>۱۱</sup> نیز به دلیل پتانسیل بالای آنها در یادگیری و سهولت تفسیر، به منظور یادگیری رابطه بین ویژگی‌های منتج از آنالیز فنی و قیمت آتی سهام استفاده شده‌اند (پاتل<sup>۱۲</sup> و همکاران، ۲۰۱۹). ماشین بردار پشتیبان<sup>۱۳</sup> و شبکه‌های عصبی مصنوعی<sup>۱۴</sup> بواسطه قابلیت بسیار برجسته در ردیابی غیرخطی، الگوریتم‌های پیشرو در کاربرد روش‌های یادگیری ماشین برای

1. Zhang
2. Wu
3. Jing
4. Wu
5. Wang
6. Nielsen
7. Autoregressive Moving Average
8. Shynkevich
9. Naive Bayes
10. Random Forests
11. K Nearest Neighbor
12. Patel
13. Support Vector Machine
14. Artificial Neural Network

مطالعات حوزه مالی می‌باشند (آتسالاکیس<sup>۱</sup> و والوانیس<sup>۲</sup>، ۲۰۰۹). شبکه‌های عصبی به عنوان یکی از مهمترین شاخه‌های یادگیری ماشین دارای مزیت‌هایی است که برخی از آنها عبارتند از: پردازش عددی، برآمدن نتایج از داده‌های اصلی، قابلیت انطباق زیاد و پتانسیل زیاد در تحلیل داده‌های غیردقیق. در سال ۱۹۸۸، وایت تغییرات در بازده روزانه سهام شرکت IBM را با استفاده از شبکه عصبی انجام داد (وایت<sup>۳</sup>، ۱۹۸۸). سپس، ژانگ مدل میانگین متحرک را با شبکه عصبی مصنوعی به منظور پیش‌بینی سری زمانی ترکیب و نتایج را مقایسه نموده و دریافت شبکه عصبی مصنوعی در تحلیل و پردازش داده‌های غیرخطی، بهتر عمل می‌نماید (ژانگ<sup>۴</sup>، ۲۰۰۳). وانستون و فینی (۲۰۰۹) یک روش تجربی مبتنی بر شبکه عصبی را برای طراحی سیستم‌های معاملاتی خودکار بر مبنای شبکه‌های عصبی مصنوعی پیشنهاد و ارائه دادند. به طور کلی، پژوهش‌های زیادی از شبکه‌های عصبی به منظور پیش‌بینی بازارهای مالی و به طور خاص قیمت سهام بهره برده‌اند (ایکان<sup>۵</sup> و سلیک<sup>۶</sup>، ۲۰۱۷).

### مروری بر ادبیات تحقیق

پیش‌بینی قیمت سهام به طور سنتی مبتنی بر مدل‌های ساده ریاضی است. محققان امور مالی در ابتدا از مدل‌های خطی ساده برای پردازش داده‌های سهام استفاده کردند، مانند مدل خودرگرسیون ساده و مدل میانگین متحرک ساده. آزمایش ریشه واحد برای بررسی میزان ثابت بودن سری‌های زمانی استفاده می‌شود (دونه<sup>۷</sup> و یورداش<sup>۸</sup>، ۲۰۱۵). با این حال، از آنجایی که داده‌های موجودی حاوی تعداد زیادی نویز و عوامل نامشخص است، با طولانی‌تر شدن دوره پیش‌بینی، محدودیت‌های مدل خطی مشخص می‌شوند (وو و همکاران، ۲۰۱۹). پژوهش‌های زیادی در داخل کشور و در سطح بازارهای بین‌المللی برای پیش‌بینی قیمت سهام با استفاده از روش‌های مختلف انجام شده‌اند که از آن جمله می‌توان به مدل خودکار رگرسیون برداری و بردار بیزی، مدل تصحیح خطا و مدل فیلتر کالمن اشاره کرد. سپس مدل‌های غیرخطی مورد استفاده قرار گرفته‌اند و روش‌های یادگیری ماشینی مانند شبکه‌های عصبی، ماشین‌های بردار پشتیبان (SVM) معرفی شده و برای پیش‌بینی سری‌های زمانی قیمت سهام به کار برده شده‌اند (داز<sup>۹</sup> و پوار<sup>۱۰</sup>، ۲۰۱۰). در سال ۱۹۸۸، وایت از یک شبکه عصبی برای پیش‌بینی قیمت سهام IBM استفاده کرد، اما نتایج

1. Atsalakis
2. Valavanis
3. White
4. Zhang
5. Ican
6. Celik
7. Dunea
8. Lordache
9. Dase
10. Pawar

خوب نبود (وایت<sup>۱</sup>، ۱۹۸۸). ژانگ در سال ۲۰۰۳ قیمت سهام را به ترتیب با استفاده از شبکه عصبی و میانگین متحرک یکپارچه اتورگرسیو (ARIMA) پیش‌بینی کرد. نتایج تجربی نشان داد که شبکه عصبی مزایای آشکاری در پیش‌بینی داده‌های غیرخطی دارد، اما دقت آن نیاز به بهبود دارد (ژانگ<sup>۲</sup>، ۲۰۰۳). وانگ و همکاران الگوریتم درخت تصمیم را با مدل SVM مخلوط کردند (وانگ<sup>۳</sup>، لیو<sup>۴</sup> و وانگ، ۲۰۱۳). آنها ابتدا بیشتر داده‌های نویز را با استفاده از الگوریتم درخت تصمیم فیلتر کردند، سپس داده‌های آموزشی مرحله دوم را با استفاده از SVM برای پیش‌بینی روند قیمت در آینده پردازش کردند. هو یو<sup>۵</sup> از CNN برای پیش‌بینی قیمت سهام استفاده کرده است. نتایج پژوهش وی نشان داد که این روش توانایی پیش‌بینی سری‌های زمانی را دارد و یادگیری عمیق برای حل مسائل سری زمانی مناسب‌تر است (هو یو، ۲۰۱۸). در داخل کشور، شریف‌فر و همکاران (۲۰۲۱) روش یادگیری عمیق LSTM را در پیش‌بینی قیمت سهام به کار برده و عملکرد LSTM را بهتر از RNN منعکس نموده‌اند. علاوه بر این، امینی‌مهر و همکاران (۲۰۲۰) از LSTM به منظور مطالعه داده‌های بازده شاخص بورس تهران بهره‌برده‌اند. با عنایت به مرور ادبیات تحقیق صورت گرفته در پژوهش حاضر، تحلیل سری زمانی قیمت‌های سهام در بازار ایران با روش BiLSTM و مدل ترکیبی PSO-BiLSTM تاکنون صورت نگرفته و به طور کلی با توجه به مرور ادبیات صورت گرفته، پژوهش‌های صورت گرفته عمدتاً به استفاده از الگوریتم‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی و انواع مختلف الگوریتم‌های یادگیری تجمعی پرداخته‌اند (احمدخان‌بیگی و عبدالوند، ۱۳۹۶؛ باباجانی و همکاران، ۱۳۹۸). جدول ۱ به بررسی مقالات و مطالعات مربوط به کاربرد انواع مختلف الگوریتم‌های یادگیری ماشین در پیش‌بینی قیمت سهام اشاره دارد.

**جدول ۱. برخی از مطالعات اخیر که از الگوریتم‌های مختلف یادگیری ماشین استفاده کرده‌اند**

نویسنده	O	DT	B	E	GA	FL	MLP	DL	LR	SVR	LSTM	BiLSTM
چردن آیالا و همکاران (۲۰۲۱)			✓				✓			✓		
پونیت میسرا و سیدارت (۲۰۲۰)			✓			✓				✓		
درانی و همکاران (۲۰۲۱)										✓	✓	
چی پراکاش و همکاران (۲۰۱۹)	✓					✓				✓		
هانگ و همکاران (۲۰۱۸)			✓									
کمیل (۲۰۱۷)			✓									
کیا و همکاران (۲۰۱۸)	✓											
بوستوس و همکاران (۲۰۱۷)						✓				✓		
چاکرابورتی و همکاران (۲۰۱۷)				✓						✓		
کاین و همکاران (۲۰۱۷)						✓						

1. White
2. Zhang
3. Liu
4. Wang
5. Hu, Y

نویسنده	O	DT	B	E	GA	FL	MLP	DL	LR	SVR	LSTM	BiLSTM
فیشر و کرایبوس (۲۰۱۸)								✓				
هو و همکاران (۲۰۱۸)							✓					
لیو و همکاران (۲۰۱۸)								✓				
مالاگرینو و همکاران (۲۰۱۸)			✓									
رن و همکاران (۲۰۱۸)									✓			
وانگ، لیو و همکاران (۲۰۱۸)		✓							✓			
وانگ، خو و همکاران (۲۰۱۸)				✓			✓		✓	✓		
ژانگ و همکاران (۲۰۱۸)				✓								
ژو و همکاران (۲۰۱۸)		✓										
لی و همکاران (۲۰۱۷)	✓											
نلسون و همکاران (۲۰۱۷)								✓				
پاگولو و همکاران (۲۰۱۶)									✓			
دینگلی و فورنیر (۲۰۱۷)								✓				
هانگ و لی (۲۰۱۷)												
سان و همکاران (۲۰۱۷)										✓		
تاننکیدیسی و همکاران (۲۰۱۷)										✓		
آروالو و همکاران (۲۰۱۷)		✓										
هونگ و انکه (۲۰۱۷)												
مک کلسکی و لیو (۲۰۱۷)												
ونگ و همکاران (۲۰۱۷)										✓		
دنگ و دونگ (۲۰۱۶)										✓		
دی پرسو و هونچار (۲۰۱۶)												
قناواتی و همکاران (۲۰۱۶)												
کیم و انکه (۲۰۱۶)												
لیباد و همکاران (۲۰۱۶)												
لینو و همکاران (۲۰۱۶)												
لی تام و همکاران (۲۰۱۶)												
مینگیو و همکاران (۲۰۱۶)												
گونزالس و همکاران (۲۰۱۵)												
چای و همکاران (۲۰۱۵)												
شینکویچ و همکاران (۲۰۱۵)												
خو و کسلج (۲۰۱۴)												
پژوهش حاضر (۲۰۲۲)		✓									✓	


SVM: ماشین بردار پشتیبان، DL: یادگیری عمیق، MLP: شبکه عصبی پرسپترون چندلایه، FL: منطق فازی، GA: الگوریتم ژنتیک، E: مدل‌های تجمعی، B: مدل‌های بیزی، DT: درخت تصمیم، LSTM: شبکه عصبی حافظه طولانی کوتاه مدت، BiLSTM: شبکه عصبی حافظه طولانی کوتاه مدت دوطرفه، LR: رگرسیون خطی، O: سایر الگوریتم‌ها



## روش‌شناسی پژوهش

این پژوهش با استفاده از الگوریتم داده‌کاوی کریسپ انجام شده است. در گام اول به مطالعه و بررسی منابع مرتبط و پیشینه پژوهش پرداخته شده و در گام بعد، داده‌های موجود در منابع مختلف، چگونگی استخراج، جمع‌آوری و تجمیع آن‌ها در دستور کار قرار گرفت. پیش‌پردازش داده‌ها گام مهم بعدی بوده و در نهایت، به مدل‌سازی و ارزیابی مدل‌ها پرداخته شد و گام‌های سوم، چهارم و پنجم به صورت مکرر تکرار و در نهایت مدل‌های نهایی تهیه گردید.

در این پژوهش قلمرو پژوهش یا به تعبیری جامعه آماری پژوهش، شرکت‌های پذیرفته شده در بورس و فرابورس اوراق بهادار تهران هستند که سهام آنها از ابتدای سال ۱۳۹۲ تا پایان سال ۱۳۹۸ معامله شده باشند، سال مالی آنها ۱۲/۲۹ باشد و بیش از سه ماه توقف معاملاتی نداشته باشند. همچنین شرکت‌های واسطه مالی از قبیل بانک‌ها، بیمه‌ها، هلدینگ‌ها و لیزینگ‌ها در این تحقیق مورد بررسی قرار نگرفته‌اند. سهام مورد مطالعه براساس نسبت P/B به صورت صعودی مرتب شده و در نهایت طبق مطالعه شن<sup>۱</sup> و تزنگ<sup>۲</sup> (۲۰۱۵)، یک سوم از آنها به عنوان سهام ارزشی انتخاب شدند. بدین ترتیب از ۱۸۰ شرکت، سهام ۶۰ شرکت از ۱۶ گروه مختلف به عنوان سهام ارزشی برگزیده شدند. جدول ۲ و شکل ۴ نام سهام ارزشی انتخاب شده و چگونگی توزیع آنها در گروه‌های مختلف را نشان می‌دهند.



شکل ۴. فراوانی سهام ارزشی انتخاب شده در گروه‌های مختلف

1. Shen
2. Tzeng

جدول ۲. سهام ارزشی انتخاب شده

نام نماد	شرکت	نام نماد	شرکت
خریخت	صنایع ریخته گری ایران	کترام	کاشی تکسرام
کحافظ	کاشی حافظ	خچرخش	چرخشگر
شرانول	نفت ایرانول	غالب	لبنیات کالبر
داراب	پتروشیمی داراب	خکار	ایرکا پارت صنعت
فرآور	فرآوری مواد معدنی	فخوز	فولاد خوزستان
فسا	پتروشیمی فسا	کچاد	چادرملو
جهرم	پتروشیمی جهرم	ستران	سیمان تهران
خبهمن	گروه بهمن	خساپا	سایپا
فولاد	فولاد مبارکه اصفهان	شتران	پالایش نفت تهران
کیسون	کیسون	رتاپ	تجارت الکترونیک پارسیان
سغوز	سیمان خوزستان	سغزر	سیمان خزر
ساراب	سیمان داراب	سغرب	سیمان غرب
فعلی	ملی صنایع مس ایران	مداران	داده پردازی ایران
دحاوی	داروسازی الحاوی	سفانو	سیمان فارس نو
تکمبا	کمیابین سازی	شاراک	پتروشیمی شازند
خدیزل	بهمن دیزل	پاسا	ایران پاسا
شپنا	پالایش نفت اصفهان	شپترو	پتروشیمی شازند
خزامیا	زامیاد	کرماشا	صنایع پتروشیمی کرمانشاه
خودرو	ایران خودرو	سلار	سیمان لارستان
فایرا	آلومینیوم ایران	فباهر	مس باهر
ذوب	ذوب آهن اصفهان	حتاید	تاید واتر خاورمیانه
سرود	سیمان شاهرود	خشرق	الکترونیک خودرو شرق
دکوثر	داروسازی کوثر	شسپا	نفت سپاهان
فاسمین	کالسیمین	خفولا	خدمات فنی فولاد یزد
رکیش	کارت اعتباری ایران کیش	کلوند	کاشی الوند
فولاز	فولاد آلیازی ایران	دلقما	داروسازی لقمان
اخابر	مخابرات ایران	خموتور	موتورسازان تراکتور
کبافق	معادن بافق	پخش	پخش البرز
کروی	معادن روی ایران	پسهند	لاستیک سپند
تایرا	تراکتورسازی	فزرین	زرین معدن آسیا

## مفاهیم و روش‌های به کار رفته در مدل

### سری‌های زمانی

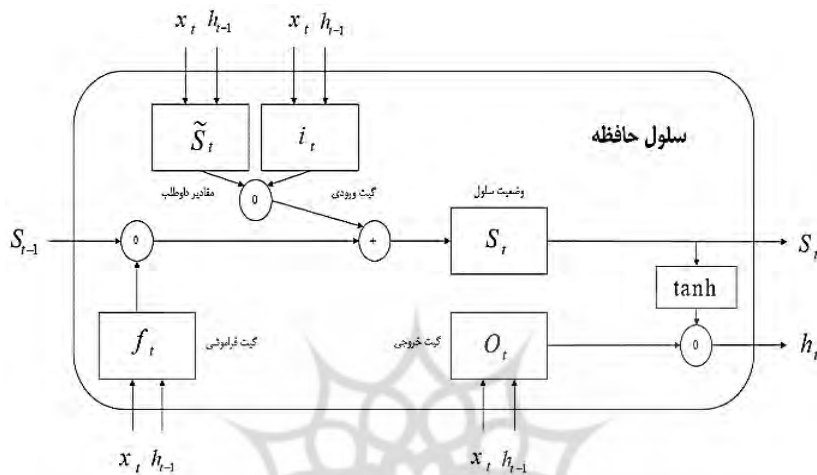
در ریاضیات، سری زمانی مجموعه‌ای از نقاط داده است که به ترتیب زمانی نمایه شده است. به طور معمول، سری زمانی دنباله‌ای است که از نقاط متوالی با فاصله زمانی یکسان گرفته می‌شود. بنابراین، این یک دنباله از داده‌های زمان گسسته است. نمونه‌هایی از سری‌های زمانی عبارتند از ارتفاعات جزر و مد اقیانوس، شمارش لکه‌های خورشیدی و ارزش بسته روزانه میانگین صنعتی داو جونز. سری‌های زمانی در آمار، پردازش سیگنال، تشخیص الگو، اقتصادسنجی، مسائل مالی، پیش‌بینی وضعیت آب و هوا، پیش‌بینی زلزله، مهندسی کنترل، نجوم، مهندسی ارتباطات و عمدتاً در هر حوزه‌ای از علوم کاربردی که شامل اندازه‌گیری‌های زمانی است استفاده می‌شوند (شاموی<sup>۱</sup> و استافر<sup>۲</sup>، ۲۰۱۷). سری‌های زمانی و تحلیل آنها در طول دو دهه گذشته تبدیل به یکی از چالش‌برانگیزترین موضوعات در حوزه داده‌کاوی بوده است (اسماعیل فواز<sup>۳</sup> و همکاران، ۲۰۱۹). با عنایت به ضرورت تحلیل و بررسی دقیق سری‌های زمانی، پژوهشگران صدها روش برای حل این مسئله ارائه داده‌اند (بگنال<sup>۴</sup>، ۲۰۱۷).

### شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM)

شبکه‌های عصبی حافظه طولانی کوتاه‌مدت از یک لایه ورودی، چندین لایه پنهان و یک لایه خروجی تشکیل شده‌اند. مهمترین ویژگی آنها سلول‌های حافظه موجود در لایه‌های پنهان است. یک واحد از شبکه عصبی حافظه طولانی کوتاه‌مدت از یک سلول، یک دروازه ورودی، یک دروازه خروجی و یک دروازه فراموشی تشکیل شده است. شکل ۲ ساختار یک سلول حافظه از این نوع شبکه عصبی را نشان می‌دهد. شبکه‌های عصبی حافظه طولانی کوتاه‌مدت، یکی از معماری‌های شبکه عصبی بازگشتی<sup>۵</sup> است که به عنوان یک جایگزین برای یادگیری الگوهای متوالی معرفی شدند و در زمینه یادگیری عمیق و تحلیل سری‌های زمانی استفاده می‌شوند (سپ هوخرایتر<sup>۶</sup> و یورگن اشمیدهور<sup>۷</sup>، ۱۹۹۶). این نوع از شبکه‌های عصبی این مزیت را دارند که اطلاعات را در یک بازه زمانی طولانی در مقایسه با شبکه‌های عصبی بازگشتی حفظ می‌کنند (فیشر<sup>۸</sup> و کراس<sup>۹</sup>، ۲۰۱۸). برخلاف شبکه‌های عصبی استاندارد، شبکه عصبی حافظه طولانی کوتاه‌مدت دارای اتصالات دارای بازخورد<sup>۱۰</sup> است که می‌تواند علاوه بر داده‌های از نوع تصویر،

1. Shumway
2. Stoffer
3. Ismail Fawaz
4. Bagnall
5. RNN
6. Sepp Hochreiter
7. Jürgen Schmidhuber
8. Fischer
9. Krauss
10. Feed Back

داده‌های ویدیو و یا صوتی را نیز پردازش کند. برای مثال، این نوع شبکه عصبی برای وظایفی مانند شناسایی دست خط، تشخیص گفتار و تشخیص ناهنجاری در ترافیک شبکه قابل استفاده است (اسماگولوا<sup>۱</sup> و جیمز<sup>۲</sup>، ۲۰۱۹).



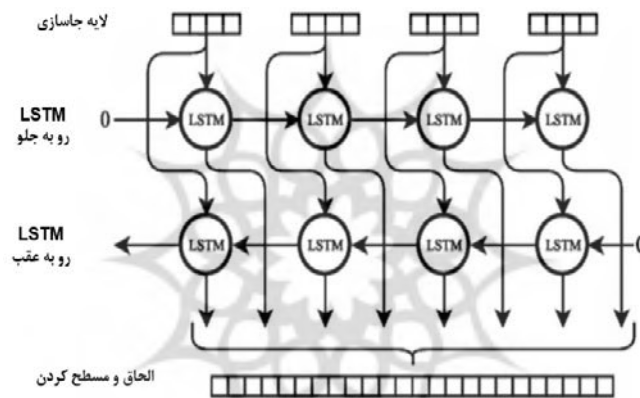
شکل ۲. ساختار یک بلوک الگوریتم LSTM (شریف‌فر و همکاران، ۲۰۲۰)

### شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه (BiLSTM)

شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه که با نام شبکه عصبی بازگشتی دوطرفه نیز شناخته می‌شود، دو لایه پنهان در جهت مخالف را به یک خروجی متصل می‌کنند. با این شکل از یادگیری عمیق مولد، لایه خروجی می‌تواند اطلاعاتی را به صورت حالت‌های رو به عقب و رو به جلو به طور همزمان دریافت می‌کند. این نوع از شبکه عصبی که در سال ۱۹۹۷ توسط شوستر<sup>۳</sup> و پالیوال<sup>۴</sup> اختراع و برای افزایش مقدار اطلاعات ورودی در دسترس شبکه ارائه شد. این الگوریتم به طور مؤثر میزان اطلاعات موجود در شبکه را افزایش می‌دهد و محتوای موجود در الگوریتم را بهبود می‌بخشد. به عنوان مثال، شبکه عصبی پرسپترون چند لایه و شبکه‌های عصبی با تأخیر زمانی، محدودیت‌هایی در انعطاف‌پذیری داده‌های ورودی دارند، زیرا به داده‌های ورودی نیاز دارند که ثابت شوند. شبکه‌های عصبی بازگشتی استاندارد نیز دارای محدودیت‌هایی هستند، زیرا نمی‌توان به اطلاعات ورودی آینده از وضعیت فعلی دسترسی پیدا کرد. برعکس، شبکه‌های عصبی بازگشتی دوطرفه نیازی ندارند که داده‌های ورودی آنها ثابت شود. علاوه بر این، اطلاعات ورودی

1. Smagulova
2. James
3. Schuster
4. Paliwal

آینده آنها از وضعیت فعلی قابل دسترسی است (صالحی نژاد<sup>۱</sup> و همکاران، ۲۰۱۷). شبکه‌های عصبی بازگشتی دو طرفه مخصوصاً زمانی مفید هستند که زمینه داده‌های ورودی مورد نیاز باشد. به عنوان مثال، در تشخیص دست خط، عملکرد را می‌توان با آگاهی از حروف واقع قبل و بعد از حرف فعلی افزایش داد. اصل این نوع شبکه این است که نورون‌های یک شبکه عصبی بازگشتی معمولی را به دو جهت تقسیم می‌کند، یکی برای جهت زمانی مثبت (حالت‌های رو به جلو) و دیگری برای جهت زمانی منفی (حالت‌های رو به عقب) (چن<sup>۲</sup> و همکاران، ۲۰۲۰). خروجی‌های آن دو حالت به ورودی‌های جهت مخالف متصل نیستند. ساختار کلی شبکه عصبی بازگشتی ساده و دو طرفه را می‌توان در شکل ۳ مشاهده کرد. با استفاده از جهت‌های دو زمانه، می‌توان از اطلاعات ورودی از گذشته و آینده چارچوب زمانی فعلی استفاده کرد، برخلاف شبکه عصبی بازگشتی ساده که برای گنجانیدن اطلاعات آینده به تأخیر نیاز دارد (شوستر و پالیوال، ۱۹۹۷).



شکل ۳. ساختار الگوریتم شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه (چن و همکاران، ۲۰۲۰)

### الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات یکی از مهم‌ترین الگوریتم‌های بهینه‌سازی هوشمند است و با الهام از رفتار اجتماعی حیواناتی چون پرندگان طراحی شده است که در گروه‌هایی کوچک و بزرگ کنار هم زندگی می‌کنند. این الگوریتم روشی مبتنی بر هوش ازدحام است که برای اولین بار توسط کندی<sup>۳</sup> و ابرهارت<sup>۴</sup> در سال ۱۹۹۵ ارائه شد (یارو لی<sup>۵</sup> و همکاران، ۲۰۲۱). این الگوریتم برای انواع مسائل پیوسته و گسسته مناسب است و پاسخ‌های بسیار مناسبی برای مسائل بهینه‌سازی مختلف ارائه می‌دهد. الگوریتم بهینه‌سازی ازدحام ذرات شامل مراحل تولید ذرات اولیه، محاسبه تابع هدف برای ذرات، تنظیم موقعیت و سرعت است. در این الگوریتم هر جواب، یک پرند در فضای جستجو است که آن را جزء می‌نامند. هر

1. Salehinejad
2. Chen
3. Kenndy
4. Eberhart
5. Yaru Li

جزء موقعیت خود را دارد و یک مقدار صلاحیت که توسط تابع صلاحیت بهینه می‌شود. برای هر ذره دو مقدار موقعیت و سرعت، تعریف می‌شود که به ترتیب با یک بردار مکان و یک بردار سرعت، مدل می‌شوند. اجزا در هر تکرار خود، بنابر جدیدترین بردار سرعت، از موقعیتی به موقعیتی دیگر می‌روند. بردار سرعت، در نتیجه تجربه هر جزء که از دیگر اجزا به دست می‌آورد و همچنین با استفاده از بهترین موقعیت در گروه، تعیین می‌شود. اعضای گروه، مکان‌های خوب را به یکدیگر از طریق ارتباط، انتقال می‌دهند و موقعیت و سرعتشان را با مکان‌های خوب تنظیم می‌کنند. در این الگوریتم هر راه حل تنها یک ذره در فضای جستجو است که عضو نامیده می‌شود. تعداد عملگرهای موجود در الگوریتم بهینه‌سازی ازدحام ذرات، به مراتب کم‌تر از سایر الگوریتم‌های فراابتکاری است. بنابراین، پیاده‌سازی این الگوریتم نسبت به الگوریتم‌هایی نظیر ژنتیک ساده‌تر و دارای حجم محاسبات کم‌تر است (لورنزو<sup>۱</sup> و همکاران، ۲۰۱۷).

الگوریتم به طور کلی دارای دو شرط خاتمه است: حداکثر تعداد تکرار و مقدار صلاحیت کافی از روی تابع صلاحیت. هنگامی که الگوریتم بهینه‌سازی ازدحام ذرات، پارامترهای الگوریتم شبکه عصبی حافظه طولانی کوتاه‌مدت ساده و دوطرفه را بهینه می‌کند، مقدار بردار موقعیت ذرات بهینه در ازدحام ذرات به ترتیب به عنوان مقدار اولیه هر وزن در هر دو شبکه استفاده می‌شود. بعد هر ذره را می‌توان با توجه به ساختار مدل شبکه عصبی محاسبه کرد و میانگین مربعات خطای هر نورون خروجی مجموعه آموزش داده شده، به عنوان تابع صلاحیت ازدحام ذرات در نظر گرفته می‌شود. سپس مقدار برازندگی هر ذره را با توجه به تابع برازش محاسبه می‌شود و هرچه مقدار آن کوچکتر باشد، خطای خروجی شبکه نیز کمتر است. این موضوع همچنین به معنای عملکرد بهتر ذرات مربوطه است. موقعیت ذرات به طور مداوم به روز می‌شود تا خطای لایه خروجی شبکه به تدریج کاهش یابد. در هر تکرار، ذره‌ای با کمترین خطا به عنوان ذره بهینه فعلی در نظر گرفته می‌شود (لیوجیا<sup>۲</sup> و همکاران، ۲۰۱۸).

### تجزیه و تحلیل داده‌ها و تفسیر نتایج عددی

#### هم مقیاس کردن ویژگی‌ها

یکی از مهم‌ترین اقدامات در پیش‌پردازش داده‌ها در مسائل پیش‌بینی قیمت سهام، هم مقیاس کردن ویژگی‌های مجموعه داده است. از جمله مزایای هم مقیاس کردن داده‌ها می‌توان به بهبود عملکرد گرادیان کاهش بر روی داده‌های نرمال شده در مقایسه با داده‌های غیر نرمال اشاره کرد. در این پژوهش از روش نرمال‌سازی جهت هم مقیاس کردن ویژگی‌ها استفاده شده است. در این روش علاوه بر یکسان‌سازی مقیاس داده‌ها، کران تغییر تمام ویژگی‌ها در بازه [۰, ۱] تبدیل خواهد شد.

$$X_{max} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

ارزیابی و اعتبارسنجی روشهای پیش‌بینی قیمت سهام با استفاده از الگوریتم‌های CART، MLP،

BiLSTM و LSTM، SVR

نتایج حاصل از پیاده‌سازی الگوریتم شبکه عصبی پرسپترون چندلایه (MLP)، درخت تصمیم طبقه‌بندی و رگرسیون (CART)، رگرسیون بردار پشتیبان (SVR)، شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM)، شبکه عصبی حافظه طولانی کوتاه‌مدت دوطرفه (BiLSTM) و همچنین شبکه عصبی حافظه طولانی کوتاه‌مدت یک‌طرفه و دوطرفه بهینه‌سازی شده با الگوریتم بهینه‌سازی ذرات (PSO) روی داده‌های سری زمانی قیمت‌های سهام انتخاب شده برای مطالعه حاضر، به شرح جدول ۳ می‌باشد. ارقام مندرج در هر ستون، نشان‌دهنده میزان خطای نرمال شده قیمت پیش‌بینی شده نسبت به قیمت واقعی است.

جدول ۳. میزان خطای نرمال شده قیمت پیش‌بینی شده نسبت به قیمت واقعی هر سهم

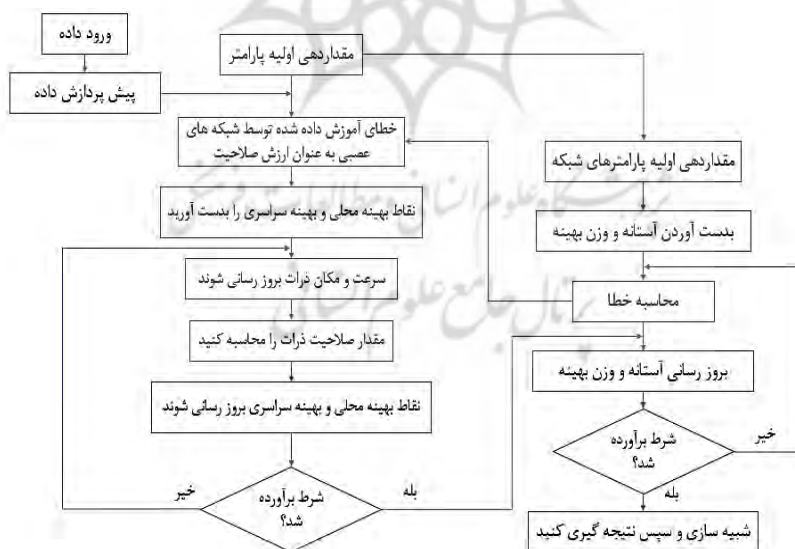
ردیف	شرکت	CART	SVR	MLP	LSTM	BiLSTM	PSO-LSTM	PSO-BiLSTM
۱	صنایع ریخته‌گری ایران	۰,۲۴۶	۰,۲۴۴	۰,۱۷۵	۰,۱۷۷	۰,۱۶۲	۰,۰۷۹	۰,۱۴۲
۲	کاشی حافظ	۰,۲۲۷	۰,۰۹۹	۰,۱۶۴	۰,۱۸۴	۰,۲۰۸	۰,۱۷۱	۰,۱۳۷
۳	نفت ایرانول	۰,۲۸۴	۰,۱۶۹	۰,۲۲۶	۰,۱۵۶	۰,۱۰۳	۰,۰۸۳	۰,۰۹۷
۴	پتروشیمی داراب	۰,۱۹۶	۰,۱۳۹	۰,۱۷۳	۰,۲۸۱	۰,۲۱۹	۰,۰۸۶	۰,۰۴۱
۵	فرآوری مواد معدنی	۰,۲۴۷	۰,۱۹۹	۰,۲۲۴	۰,۲۹۴	۰,۱۳۶	۰,۰۳۸	۰,۰۹۵
۶	پتروشیمی فسا	۰,۱۶۶	۰,۱۳۵	۰,۱۶۷	۰,۲۴۲	۰,۲۰۷	۰,۱۸۰	۰,۰۲۸
۷	پتروشیمی جهرم	۰,۱۷۵	۰,۰۹۴	۰,۰۶۶	۰,۲۶۶	۰,۲۰۳	۰,۱۴۳	۰,۱۱۶
۸	گروه بهمن	۰,۱۳۹	۰,۱۵۳	۰,۲۶۰	۰,۰۵۲	۰,۱۵۲	۰,۱۰۴	۰,۰۸۵
۹	فولاد مبارکه اصفهان	۰,۲۴۰	۰,۱۲۳	۰,۲۸۹	۰,۱۱۴	۰,۱۴۴	۰,۱۷۰	۰,۱۰۷
۱۰	کیسون	۰,۱۳۴	۰,۲۰۷	۰,۲۲۶	۰,۲۰۴	۰,۰۵۱	۰,۰۹۴	۰,۰۸۴
۱۱	سیمان خوزستان	۰,۲۶۴	۰,۱۵۲	۰,۱۸۱	۰,۱۸۷	۰,۲۱۵	۰,۱۶۳	۰,۱۴۴
۱۲	سیمان داراب	۰,۲۰۳	۰,۲۴۵	۰,۰۷۰	۰,۱۹۱	۰,۰۷۹	۰,۰۹۲	۰,۰۷۵
۱۳	ملی صنایع مس ایران	۰,۲۵۴	۰,۱۱۲	۰,۱۳۵	۰,۱۴۵	۰,۱۶۹	۰,۰۸۴	۰,۱۴۷
۱۴	داروسازی الحاوی	۰,۲۰۰	۰,۱۹۰	۰,۲۵۸	۰,۲۵۸	۰,۱۷۹	۰,۱۷۶	۰,۰۴۶
۱۵	کمباین‌سازی	۰,۲۹۰	۰,۱۶۲	۰,۲۸۲	۰,۱۳۷	۰,۲۰۰	۰,۱۷۴	۰,۱۳۱
۱۶	بهمن دیزل	۰,۲۹۷	۰,۰۸۱	۰,۱۱۰	۰,۱۶۳	۰,۰۸۹	۰,۱۷۵	۰,۱۳۱
۱۷	پالایش نفت اصفهان	۰,۲۹۶	۰,۲۶۸	۰,۰۶۹	۰,۱۰۰	۰,۱۹۵	۰,۰۷۴	۰,۰۴۲
۱۸	زامیاد	۰,۲۶۷	۰,۰۹۶	۰,۱۰۸	۰,۲۱۵	۰,۲۳۱	۰,۱۰۳	۰,۰۵۸
۱۹	ایران خودرو	۰,۱۶۸	۰,۱۱۵	۰,۱۵۴	۰,۲۳۳	۰,۰۶۳	۰,۱۸۷	۰,۱۴۲
۲۰	آلومینیوم ایران	۰,۲۹۱	۰,۲۲۰	۰,۲۷۹	۰,۲۱۳	۰,۰۷۶	۰,۱۶۷	۰,۱۰۷
۲۱	ذوب آهن اصفهان	۰,۲۶۵	۰,۱۷۱	۰,۱۶۵	۰,۲۵۱	۰,۱۸۸	۰,۱۰۹	۰,۱۲۴

ردیف	شرکت	CART	SVR	MLP	LSTM	BiLSTM	PSO-LSTM	PSO-BiLSTM
۲۲	سیمان شاهرود	۰,۳۴۵	۰,۰۷۵	۰,۳۰۶	۰,۲۳۹	۰,۰۴۸	۰,۰۴۸	۰,۰۹۹
۲۳	داروسازی کوثر	۰,۳۲۴	۰,۱۹۳	۰,۱۵۱	۰,۲۰۰	۰,۱۱۵	۰,۰۵۱	۰,۰۵۴
۲۴	کالسیمین	۰,۲۸۲	۰,۲۲۰	۰,۲۳۲	۰,۰۵۹	۰,۰۹۶	۰,۰۷۶	۰,۰۵۴
۲۵	کارت اعتباری ایران کیش	۰,۳۶۵	۰,۲۷۶	۰,۰۹۸	۰,۲۱۶	۰,۱۸۸	۰,۰۸۶	۰,۰۹۲
۲۶	فولاد آلیاژی ایران	۰,۱۳۸	۰,۲۸۴	۰,۲۵۳	۰,۱۳۰	۰,۲۱۴	۰,۰۷۱	۰,۰۲۵
۲۷	مخابرات ایران	۰,۳۵۹	۰,۱۳۴	۰,۲۵۹	۰,۰۶۷	۰,۱۸۹	۰,۱۶۵	۰,۰۸۶
۲۸	معادن بافق	۰,۱۲۸	۰,۱۳۲	۰,۰۶۵	۰,۱۵۰	۰,۲۲۵	۰,۰۴۰	۰,۱۰۲
۲۹	معادن روی ایران	۰,۲۶۳	۰,۱۵۳	۰,۲۸۱	۰,۰۶۳	۰,۲۲۱	۰,۱۹۱	۰,۰۷۶
۳۰	تراکتورسازی	۰,۲۸۱	۰,۱۶۳	۰,۱۳۷	۰,۱۹۵	۰,۱۷۲	۰,۰۷۲	۰,۰۸۱
۳۱	کاشی تکسرام	۰,۲۳۳	۰,۲۳۶	۰,۱۶۸	۰,۰۵۱	۰,۰۶۵	۰,۰۴۶	۰,۰۷۲
۳۲	چرخشگر	۰,۳۳۹	۰,۲۸۴	۰,۲۱۴	۰,۲۲۰	۰,۰۸۲	۰,۰۵۲	۰,۰۳۵
۳۳	لبنیات کالبر	۰,۲۰۴	۰,۲۵۲	۰,۱۹۸	۰,۲۴۲	۰,۲۲۴	۰,۱۲۳	۰,۰۸۲
۳۴	ایرکا پارت صنعت	۰,۱۵۱	۰,۱۸۹	۰,۱۴۵	۰,۰۸۲	۰,۱۳۰	۰,۰۷۶	۰,۰۳۹
۳۵	فولاد خوزستان	۰,۲۱۸	۰,۱۵۴	۰,۲۸۸	۰,۱۰۵	۰,۰۶۲	۰,۰۷۵	۰,۰۴۵
۳۶	چادرملو	۰,۲۷۰	۰,۱۹۷	۰,۲۸۶	۰,۲۳۷	۰,۱۹۴	۰,۰۸۹	۰,۰۹۸
۳۷	سیمان تهران	۰,۱۶۸	۰,۱۶۰	۰,۱۵۶	۰,۰۷۱	۰,۲۲۹	۰,۱۰۲	۰,۱۱۱
۳۸	سایپا	۰,۱۴۶	۰,۱۱۱	۰,۲۳۳	۰,۲۴۶	۰,۱۱۲	۰,۱۷۸	۰,۱۲۹
۳۹	پالایش نفت تهران	۰,۱۵۹	۰,۱۳۵	۰,۱۹۹	۰,۰۵۱	۰,۰۷۸	۰,۱۲۰	۰,۱۳۰
۴۰	تجارت الکترونیک پارسیان	۰,۱۸۱	۰,۱۹۶	۰,۲۶۰	۰,۱۳۹	۰,۱۸۵	۰,۱۴۸	۰,۰۲۷
۴۱	سیمان خزر	۰,۲۳۹	۰,۱۷۱	۰,۱۹۹	۰,۱۹۲	۰,۰۸۷	۰,۰۷۶	۰,۱۳۶
۴۲	سیمان غرب	۰,۲۱۸	۰,۱۵۰	۰,۱۲۲	۰,۱۱۶	۰,۰۸۲	۰,۱۸۸	۰,۰۷۷
۴۳	داده پردازی ایران	۰,۱۵۲	۰,۱۴۶	۰,۲۵۱	۰,۲۵۹	۰,۱۸۵	۰,۱۳۲	۰,۰۸۴
۴۴	سیمان فارس نو	۰,۳۵۸	۰,۰۸۶	۰,۱۲۶	۰,۲۷۱	۰,۰۸۹	۰,۱۸۴	۰,۰۸۲
۴۵	پتروشیمی شازند	۰,۱۴۳	۰,۰۸۵	۰,۲۲۰	۰,۰۸۱	۰,۲۲۷	۰,۱۴۲	۰,۱۳۳
۴۶	ایران یاسا	۰,۲۴۱	۰,۲۶۰	۰,۱۱۳	۰,۱۱۱	۰,۱۴۷	۰,۰۸۰	۰,۰۵۲
۴۷	پتروشیمی شازند	۰,۲۸۲	۰,۰۹۹	۰,۰۹۶	۰,۰۶۱	۰,۰۹۷	۰,۰۷۷	۰,۱۲۲
۴۸	صنایع پتروشیمی کرمانشاه	۰,۳۰۳	۰,۱۶۵	۰,۲۵۸	۰,۲۰۴	۰,۱۴۴	۰,۱۲۱	۰,۰۹۳
۴۹	سیمان لارستان	۰,۲۰۶	۰,۱۴۶	۰,۲۹۸	۰,۱۷۳	۰,۱۵۱	۰,۱۴۱	۰,۰۳۴
۵۰	مس باهنر	۰,۲۸۸	۰,۱۷۳	۰,۱۶۶	۰,۲۶۳	۰,۰۸۰	۰,۱۳۲	۰,۰۴۵



ردیف	شرکت	CART	SVR	MLP	LSTM	BiLSTM	PSO-LSTM	PSO-BiLSTM
۵۱	تایید واتر خاورمیانه	۰,۲۶۶	۰,۲۲۹	۰,۲۲۹	۰,۲۱۲	۰,۱۴۱	۰,۱۳۶	۰,۱۰۸
۵۲	الکترونیک خودرو شرق	۰,۳۲۸	۰,۰۷۸	۰,۲۱۹	۰,۱۳۰	۰,۱۲۱	۰,۱۶۸	۰,۱۰۵
۵۳	نفت سپاهان	۰,۲۱۹	۰,۲۳۶	۰,۲۶۷	۰,۱۱۰	۰,۱۴۱	۰,۱۸۲	۰,۱۲۷
۵۴	خدمات فنی فولاد یزد	۰,۳۳۶	۰,۱۱۱	۰,۲۰۲	۰,۲۶۱	۰,۲۳۳	۰,۱۲۵	۰,۰۵۲
۵۵	کاشی الوند	۰,۱۴۵	۰,۲۰۶	۰,۲۳۰	۰,۰۵۹	۰,۰۹۲	۰,۰۹۷	۰,۱۱۶
۵۶	داروسازی لقمان	۰,۲۴۰	۰,۲۷۸	۰,۰۷۳	۰,۲۴۸	۰,۰۶۴	۰,۱۴۶	۰,۱۳۳
۵۷	موتورسازان تراکتور	۰,۳۲۲	۰,۱۹۱	۰,۲۶۰	۰,۲۴۷	۰,۱۹۵	۰,۱۴۹	۰,۱۰۰
۵۸	پخش البرز	۰,۱۳۸	۰,۱۴۰	۰,۰۷۱	۰,۲۵۸	۰,۱۱۷	۰,۱۸۱	۰,۰۴۴
۵۹	لاستیک سهند	۰,۲۵۵	۰,۱۹۹	۰,۲۷۴	۰,۲۵۶	۰,۲۰۴	۰,۰۵۷	۰,۱۳۶
۶۰	زرین معدن آسیا	۰,۲۲۶	۰,۲۸۳	۰,۱۸۴	۰,۱۶۱	۰,۱۷۳	۰,۱۳۶	۰,۱۱۱

در فرآیند توسعه و پیاده‌سازی مدل ترکیبی به کار برده شده در این پژوهش، پارامترهای الگوریتم شبکه عصبی حافظه طولانی کوتاه‌مدت یک‌طرفه (LSTM) و دوطرفه (BiLSTM) با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) بهینه گردیده‌اند که چگونگی آن به شرح شکل ۵ می‌باشد و مقادیر بهینه بدست آمده از این روش برای پارامترهای BiLSTM در جدول ۴ نشان داده شده‌اند.



شکل ۵. فلوجارت بهینه‌سازی پارامترهای شبکه‌های عصبی حافظه طولانی کوتاه‌مدت توسط PSO

**جدول ۴.** پارامترهای بهینه در مدل BiLSTM روی داده‌های سری زمانی

پارامتر مدل	مقدار
اندازه دسته	۱۲۸
تابع فعال‌ساز	tanh
نرخ یادگیری اولیه	۰,۰۰۱
نرخ حذف تصادفی	۰,۱۵
حداکثر تعداد تکرار	۱۵۰
بهینه‌ساز وزن‌های شبکه	Adam
معیار سنجش	میانگین مجذور مربعات خطا
تعداد لایه‌های پنهان	۲
تعداد نوروں‌های لایه‌ها	لایه اول: ۴ لایه دوم: ۲

### معیار ارزیابی

برای ارزیابی عملکرد مدل‌های رگرسیونی ساخته شده در این پژوهش از معیارهای ارزیابی میانگین مجذور مربعات خطا<sup>۱</sup> و ضریب تعیین رگرسیون<sup>۲</sup> استفاده شده است. میانگین مجذور مربعات خطا در واقع تفاوت میان مقدار پیش‌بینی شده توسط مدل یا برآوردگر آماری و مقدار واقعی می‌باشد. این معیار یک ابزار مناسب برای مقایسه خطاهای پیش‌بینی توسط یک مجموعه داده است و برای مقایسه چند مجموعه داده کاربرد ندارد (هیندمن<sup>۳</sup> و همکاران، ۲۰۰۶). فرمول محاسبه میانگین مجذور مربعات خطا بدین صورت است که در آن  $\hat{y}_i$  مقدار پیش‌بینی شده و  $y_i$  مقدار واقعی است. هر چه مقدار این معیار کوچکتر باشد، مدل پیش‌بینی دقیق‌تری انجام داده است.

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

ضریب تعیین رگرسیون، یکی از شاخص‌های برازش مدل است که قدرت پیش‌بینی متغیر وابسته براساس متغیرهای مستقل را نشان می‌دهد (ونجی لو<sup>۴</sup> و همکاران، ۲۰۲۰). فرمول محاسبه ضریب تعیین رگرسیون بدین صورت است که در آن  $\hat{y}_i$  مقدار پیش‌بینی شده،  $y_i$  مقدار واقعی و  $\bar{y}_i$  مقدار متوسط است. محدوده این معیار [۰,۱] است که هر چه به ۱ نزدیک‌تر باشد، مدل عملکرد بهتری در پیش‌بینی متغیر وابسته دارد.

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

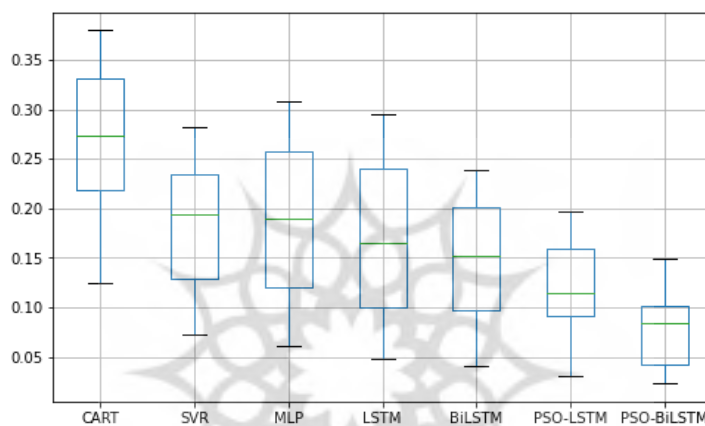
### تفسیر نتایج

در این پژوهش دوره زمانی مدل به دو بازه دوره آموزش مدل و دوره آزمایش آن تقسیم شده است. در دوره آموزش، اطلاعات جمع‌آوری شده از داده‌های سری زمانی قیمتی سهام مورد نظر از ابتدای سال

1. RMSE
2. R-Square
3. Hyndman
4. Wenjie Lu

۱۳۹۲ تا پایان سال ۱۳۹۷ و در دوره آزمایش، اطلاعات یاد شده از ابتدا تا پایان سال ۱۳۹۸ در نظر گرفته شده‌اند. تمامی مراحل اجرا در رایانه شخصی با مشخصات سیستم عامل Windows 10, core i5 و با استفاده از زبان برنامه‌نویسی پایتون انجام شده است.

همانطور که از شکل ۶ قابل مشاهده است، پراکندگی خطای نرمال شده قیمت پیش‌بینی شده نسبت به قیمت واقعی هر سهم با استفاده از مدل ترکیبی الگوریتم حافظه طولانی کوتاه‌مدت دوطرفه و بهینه‌سازی ازدحام ذرات (PSO-BiLSTM) در مقایسه با سایر الگوریتم‌های یادگیری ماشین پیاده‌سازی شده کمتر است. لذا این مدل ترکیبی، بهترین روش با کمترین خطا در پیش‌بینی قیمت سهام مورد مطالعه بوده است.



شکل ۶. نحوه پراکندگی خطا مدل‌های ساخته شده بر روی داده‌های سری زمانی

علاوه بر این، همانطور که از نتایج جدول ۵ نیز مشاهده می‌شود مدل ترکیبی BiLSTM-PSO نسبت به سایر مدل‌ها عملکرد بهتری دارد. این مدل دارای معیار  $R^2$  برابر با ۰/۸۹ است که بیشترین مقدار را دارد. همچنین این مدل دارای معیار RMSE برابر با ۱۶۰/۸۴۹ می‌باشد که کمترین مقدار را در بین سایر مدل‌ها دارد. لذا در استفاده از داده‌های مشخصات قیمتی سهام ارزشی مورد مطالعه در این پژوهش، مدل ترکیبی PSO-BiLSTM عملکرد بهتری نسبت به سایر روشها دارد.

جدول ۵. میزان  $R^2$  و RMSE مدل‌های ساخته شده با استفاده از سری زمانی قیمت‌های سهام مورد مطالعه

مدل	RMSE	$R^2$
CART	۲۴۷/۴۳۸۷	۰/۵۶
SVR	۲۱۹/۴۹۸۴	۰/۶۷
MLP	۲۳۰/۱۷۶۸	۰/۶۱
LSTM	۲۰۶/۱۶۳۱	۰/۷۲
BiLSTM	۱۷۳/۶۳۷	۰/۷۶
PSO-LSTM	۱۶۶/۴۹۰	۰/۸۵
PSO-BiLSTM	۱۶۰/۸۴۹	۰/۸۹

## بحث و نتیجه‌گیری

در این پژوهش از داده‌های سری زمانی قیمت سهام ۶۰ شرکت فعال در بازار اوراق بهادار تهران و فرابورس ایران به عنوان سهام ارزشی استفاده شد. سهام ارزشی، سهامی است که می‌توان گفت در بازار قیمت پایین‌تری نسبت به ارزش ذاتی خود دارند که در این پژوهش از نسبت P/B به منظور تشخیص سهام ارزشی استفاده شده است. جهت اجرای مدل‌های پیش‌بینی، اطلاعات مربوط به سهام از سال ۱۳۹۲ تا ۱۳۹۷ به عنوان داده‌های آموزش و اطلاعات سال ۱۳۹۸ به عنوان داده‌های آزمایش در نظر گرفته شدند. همانگونه که نتایج در جدول ۳ شکل ۶ نشان داد استفاده از مدل ترکیبی PSO-BiLSTM در پیش‌بینی قیمت سهام نسبت به سایر الگوریتم‌های یادگیری ماشین بهتر عمل کرده و خطای کمتری دارد. همچنین معیارهای ارزیابی عملکرد RMSE و R-Square نتایج عددی و فرضیه تحقیق مبنی بر عملکرد بهتر PSO-BiLSTM نسبت به سایر روش‌های مرسوم را تأیید نموده و نشان دادند که مدل ترکیبی PSO-BiLSTM با R-Square برابر با ۰/۸۹ با بیشترین مقدار نزدیک به یک، و RMSE برابر با ۱۶۰/۸۴۹ با کمترین مقدار، عملکرد بهتری نسبت به دیگر الگوریتم‌های مرسوم شامل MLP، CART، SVR، LSTM، BiLSTM و PSO-LSTM دارد و خطای آن در پیش‌بینی قیمت‌های سهام مورد مطالعه کمتر است.

## پیشنهاد‌های آتی

برای پژوهش‌های آتی می‌توان به جای استفاده از مشخصه‌های قیمتی سهام (سری زمانی)، از داده‌های مربوط به تحلیل تکنیکال و تحلیل بنیادی استفاده نمود. همچنین، پیشنهاد می‌شود روش پیاده‌سازی شده در این پژوهش بر سری زمانی قیمت سایر سهام‌ها در بازار ایران نیز استفاده شود. علاوه بر این، می‌توان در تنظیم پارامترهای الگوریتم‌های یادگیری ماشین، از الگوریتم‌های فراابتکاری دیگر نظیر الگوریتم ژنتیک، کلونی مورچگان، شبیه‌سازی تبرید و غیره استفاده و نتایج را با هم تطبیق و مقایسه نمود.

## ملاحظات اخلاقی

حامی مالی: مقاله حامی مالی ندارد.  
 مشارکت نویسندگان: تمام نویسندگان در آماده‌سازی مقاله مشارکت داشته‌اند.  
 تعارض منافع: بنا بر اظهار نویسندگان در این مقاله هیچ‌گونه تعارض منافی وجود ندارد.  
 تعهد کپی‌رایت: طبق تعهد نویسندگان حق کپی‌رایت رعایت شده است.

## References

- Aguilar-Rivera, A., & Valenzuela-Rendón, M. (2019). A new multi-period investment strategies method based on evolutionary algorithms. *Neural Computing and Applications*, 31(3), 923-937.
- AhmadKhanBeygi, S., & Abdolvand, N. (2017). Stock Price Prediction Modeling Using Artificial Neural Network Approach and Imperialist Competitive Algorithm Based On Chaos Theory. *Financial Management Strategy*, 5(3), 27-73. (In persian).
- Aminimehr, A., Bajalan, S., & Hekmat, H. (2021). A study on the characteristics of TSE index return data and introducing a regime switching prediction method based on neural networks. *Journal of Financial Management Perspective*, 11(34).
- Arévalo, R., García, J., Guijarro, F., & Peris, A. (2017). A dynamic trading rule based on filtered flag pattern recognition for stock market price forecasting. *Expert Systems with Applications*, 81, 177-192.
- Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques–Part II: Soft computing methods. *Expert Systems with Applications*, 36(3), 5932-5941.
- Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F., & Divina, F. (2021). Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, 225, 107119.
- Babajani, J., Taghva, M., Blue, G., & Abdollahi, M. (2019). Forecasting Stock Prices In Tehran Stock Exchange Using Recurrent Neural Network Optimized by Artificial Bee Colony Algorithm. *Financial Management Strategy*, 7(2), 195-228. (In persian).
- Bagnall, A., Lines, J., Bostrom, A., Large, J., & Keogh, E. (2017). The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data mining and knowledge discovery*, 31(3), 606-660.
- Bustos, O., Pomares, A., & Gonzalez, E. (2017). A comparison between SVM and multilayer perceptron in predicting an emerging financial market: Colombian stock market. 2017 Congreso Internacional de Innovacion y Tendencias en Ingenieria (CONIITI),
- Chai, J., Du, J., Lai, K. K., & Lee, Y. P. (2015). A hybrid least square support vector machine model with parameters optimization for stock forecasting. *Mathematical Problems in Engineering*, 2015.
- Chakraborty, P., Priya, U. S., Rony, M. R. A. H., & Majumdar, M. A. (2017). Predicting stock movement using sentiment analysis of Twitter feed. 2017 6th International Conference on Informatics, Electronics and Vision & 2017 7th International Symposium in Computational Medical and Health Technology (ICIEV- ISCMHT),
- Chen, Q., Zhang, W., & Lou, Y. (2020). Forecasting stock prices using a hybrid deep learning model integrating attention mechanism, multi-layer perceptron, and bidirectional long-short term memory neural network. *IEEE Access*, 8, 117365-117376.
- Coyne, S., Madiraju, P., & Coelho, J. (2017). Forecasting stock prices using social media analysis. 2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress (DASC/PiCom/DataCom/CyberSciTech),

- Dang, M., & Duong, D. (2016). Improvement methods for stock market prediction using financial news articles. 2016 3rd National Foundation for Science and Technology Development Conference on Information and Computer Science (NICS),
- Dase, R., & Pawar, D. (2010). Application of Artificial Neural Network for stock market predictions: A review of literature. *International Journal of Machine Intelligence*, 2(2), 14-17.
- Dechow, P. M., Hutton, A. P., Meulbroek, L., & Sloan, R. G. (2001). Short-sellers, fundamental analysis, and stock returns. *Journal of financial Economics*, 61(1), 77-106.
- Dharani, N., Bojja, P., & Kumari, P. R. (2021). Evaluation of performance of an LR and SVR models to predict COVID-19 pandemic. *Materials Today: Proceedings*.
- Di Persio, L., & Honchar, O. (2016). Artificial neural networks architectures for stock price prediction: Comparisons and applications. *International journal of circuits, systems and signal processing*, 10(2016), 403-413.
- Dingli, A., & Fournier, K. S. (2017). Financial time series forecasting—a deep learning approach. *International Journal of Machine Learning and Computing*, 7(5), 118-122.
- Dunea, D., & Iordache, S. (2015). TIME SERIES ANALYSIS OF AIR POLLUTANTS RECORDED FROM ROMANIAN EMEP STATIONS AT MOUNTAIN SITES. *Environmental Engineering & Management Journal (EEMJ)*, 14(11).
- Edwards, R. D., Magee, J., & Bassetti, W. C. (2018). *Technical analysis of stock trends*. CRC press.
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
- Ghanavati, M., Wong, R. K., Chen, F., Wang, Y., & Fong, S. (2016). A generic service framework for stock market prediction. 2016 IEEE International Conference on Services Computing (SCC),
- Gonzalez, R. T., Padilha, C. A., & Barone, D. A. C. (2015). Ensemble system based on genetic algorithm for stock market forecasting. 2015 IEEE congress on evolutionary computation (CEC),
- Hochreiter, S., & Schmidhuber, J. (1996). LSTM can solve hard long time lag problems. *Advances in neural information processing systems*, 9.
- Hu, Y. (2018). Stock market timing model based on convolutional neural network—a case study of Shanghai composite index. *Finance & Economy*, 4, 71-74.
- Huang, C.-F., & Li, H.-C. (2017). An evolutionary method for financial forecasting in microscopic high-speed trading environment. *Computational Intelligence and Neuroscience*, 2017.
- Huang, Q., Kong, Z., Li, Y., Yang, J., & Li, X. (2018). Discovery of trading points based on Bayesian modeling of trading rules. *World Wide Web*, 21(6), 1473-1490.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688.
- Ican, O., & Celik, T. B. (2017). Stock market prediction performance of neural networks: A literature review. *International Journal of Economics and Finance*, 9(11), 100-108.

Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., & Muller, P.-A. (2019). Deep learning for time series classification: a review. *Data mining and knowledge discovery*, 33(4), 917-963.

Jing, N., Wu, Z., & Wang, H. (2021). (A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction. *Expert Systems with Applications*, 178, 115019.

Kamble, R. A. (2017). Short and long term stock trend prediction using decision tree. 2017 International Conference on Intelligent Computing and Control Systems (ICICCS),

Kelleher, J. D. (2019). *Deep learning*. MIT press.

Khashei, M., Bijari, M., & Ardali, G. A. R. (2012). Hybridization of autoregressive integrated moving average (ARIMA) with probabilistic neural networks (PNNs). *Computers & Industrial Engineering*, 63(1), 37-45.

Kia, A. N., Haratizadeh, S., & Shouraki, S. B. (2018). A hybrid supervised semi-supervised graph-based model to predict one-day ahead movement of global stock markets and commodity prices. *Expert Systems with Applications*, 105, 159-173.

Kim, K.-j., & Han, I. (2000). Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert Systems with Applications*, 19(2), ۱۲۵-۱۳۲.

Kim, Y., & Enke, D. (2016). Developing a rule change trading system for the futures market using rough set analysis. *Expert Systems with Applications*, 59, 165-173.

Labiad, B., Berrado, A., & Benabbou, L. (2016). Machine learning techniques for short term stock movements classification for moroccan stock exchange. 2016 11th International Conference on Intelligent Systems: Theories and Applications (SITA),

Leitao, J., Neves, R. F., & Horta, N. (2016). Combining rules between PIPs and SAX to identify patterns in financial markets. *Expert Systems with Applications*, 65, 242-254.

Li, B., Chan, K. C., Ou, C., & Ruifeng, S. (2017). Discovering public sentiment in social media for predicting stock movement of publicly listed companies. *Information Systems*, 69, 81-92.

Li, Y., Zhang, Y., Zhou, G., & Gong, Y. (2021). Bayesian Optimization with Particle Swarm. 2021 International Joint Conference on Neural Networks (IJCNN),

Li, Z., Tam, V., & Yeung, L. (2016). Combining cloud computing, machine learning and heuristic optimization for investment opportunities forecasting. 2016 IEEE Congress on Evolutionary Computation (CEC),

Liu, Y., Gong, C., Yang, L., & Chen, Y. (2020). DSTP-RNN: A dual-stage two-phase attention-based recurrent neural network for long-term and multivariate time series prediction. *Expert Systems with Applications*, 143, 113082.

Liu, Y., Zeng, Q., Yang, H., & Carrio, A. (2018). Stock price movement prediction from financial news with deep learning and knowledge graph embedding. Pacific rim knowledge acquisition workshop,

Lorenzo, P. R., Nalepa, J., Kawulok, M., Ramos, L. S., & Pastor, J. R. (2017). Particle swarm optimization for hyper-parameter selection in deep neural networks. Proceedings of the genetic and evolutionary computation conference,

Lv, L., Kong, W., Qi, J., & Zhang, J. (2018). An improved long short-term memory neural network for stock forecast. MATEC web of conferences,

Malagrino, L. S., Roman, N. T., & Monteiro, A. M. (2018). Forecasting stock market index daily direction: A Bayesian Network approach. *Expert Systems with Applications*, 105, 11-22.

McCluskey, J., & Liu, J. (2017). US financial market forecasting using data classification with features from global markets. 2017 2nd International Conference on Image, Vision and Computing (ICIVC),

Mingyue, Q., Cheng, L., & Yu, S. (2016). Application of the Artificial Neural Network in predicting the direction of stock market index. 2016 10th International Conference on Complex, Intelligent, and Software Intensive Systems (CISIS),

Misra, P., & Chaurasia, S. (2020). Data-driven trend forecasting in stock market using machine learning techniques. *Journal of Information Technology Research (JITR)*, 13(1), 130-149.

Nelson, D. M., Pereira, A. C., & De Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. 2017 International joint conference on neural networks (IJCNN),

Nielsen, A. (2019). *Practical time series analysis: Prediction with statistics and machine learning*. O'Reilly Media.

Oberlechner, T. (2001). Importance of technical and fundamental analysis in the European foreign exchange market. *International Journal of Finance & Economics*, 6(1), 81-93.

Pagolu, V. S., Reddy, K. N., Panda, G., & Majhi, B. (2016). Sentiment analysis of Twitter data for predicting stock market movements. 2016 international conference on signal processing, communication, power and embedded system (SCOPE5),

Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert Systems with Applications*, 42(1), 259-268.

Rather, A. M., Agarwal, A., & Sastry, V. (2015). Recurrent neural network and a hybrid model for prediction of stock returns. *Expert Systems with Applications*, 42(6), 3234-3241.

Ren, R., Wu, D. D., & Liu, T. (2018). Forecasting stock market movement direction using sentiment analysis and support vector machine. *IEEE Systems Journal*, 13(1), 760-770.

Sadeh, e., Ehtesham Rasi, r & ., Sheidaei Narmigi, a. (2017). Fuzzy – neural model with hybrid genetic algorithms for stock price forecasting in auto industry in Tehran security exchange. *Financial Engineering and Portfolio Management*, 8(33), 113-136. (In persian).

Salehinejad, H., Sankar, S., Barfett, J., Colak, E., & Valaee, S. (2017). Recent advances in recurrent neural networks. *arXiv preprint arXiv:1801.01078*.

Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE transactions on Signal Processing*, 45(11), 2673-2681.

Sharif far, A., Khalili Araghi, M., Raeesi Vanani, I., & Fallah, M. (2021). The Assessment of the optimal Deep Learning Algorithm on Stock Price Prediction (Long Short-Term Memory Approach). *Financial Engineering and Portfolio Management*, 12(48), 348-370. (In Persian).

Shumway, R. H., Stoffer, D. S., & Stoffer, D. S. (2000). *Time series analysis and its applications* (Vol. 3). Springer.



Shynkevich, Y., McGinnity, T. M., Coleman, S., & Belatreche, A. (2015). Stock price prediction based on stock-specific and sub-industry-specific news articles. 2015 international joint conference on neural networks (ijcnn),

Shynkevich, Y., McGinnity, T. M., Coleman, S. A., Belatreche, A., & Li, Y. (2017). Forecasting price movements using technical indicators: Investigating the impact of varying input window length. *Neurocomputing*, 264, 71-88.

Smagulova, K., & James, A. P. (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313-2324.

Sun, T., Wang, J., Zhang, P., Cao, Y., Liu, B., & Wang, D. (2017). Predicting stock price returns using microblog sentiment for chinese stock market. 2017 3rd International Conference on Big Data Computing and Communications (BIGCOM),

Tsantekidis, A., Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2017). Using deep learning to detect price change indications in financial markets. 2017 25th European Signal Processing Conference (EUSIPCO),

Vanstone, B., & Finnie, G. (2009). An empirical methodology for developing stockmarket trading systems using artificial neural networks. *Expert Systems with Applications*, 36(3), 6668-6680.

Vassiliadis, V., Thomaidis, N., & Dounias, G. (2011). On the performance and convergence properties of hybrid intelligent schemes: application on portfolio optimization domain. European Conference on the Applications of Evolutionary Computation,

Verma, J. P., Tanwar, S., Garg, S., Gandhi, I., & Bachani, N. H. (2019). Evaluation of pattern based customized approach for stock market trend prediction with big data and machine learning techniques. *International Journal of Business Analytics (IJBAN)*, 6(3), 1-15.

Wang, D., Liu, X., & Wang, M. (2013). A DT-SVM strategy for stock futures prediction with big data. 2013 IEEE 16th International Conference on Computational Science and Engineering,

Wang, J., Shang, W., Liu, Z., & Wang, S. (2017). An enhanced LGSA-SVM for S&P 500 index forecast. 2017 IEEE International Conference on Big Data (Big Data),

Wang, Q., Xu, W., & Zheng, H. (2018). Combining the wisdom of crowds and technical analysis for financial market prediction using deep random subspace ensembles. *Neurocomputing*, 299, 51-61.

White, H. (1988). Economic prediction using neural networks: The case of IBM daily stock returns. ICNN,

Wu, Z., Fan, J., Gao, Y., Shang, H., & Song, H. (2019). STUDY ON PREDICTION MODEL OF SPACE-TIME DISTRIBUTION OF AIR POLLUTANTS BASED ON ARTIFICIAL NEURAL NETWORK. *Environmental Engineering & Management Journal (EEMJ)*, 18(7).

Xu, F., & Keelj, V. (2014). Collective sentiment mining of microblogs in 24-hour stock price movement prediction. 2014 IEEE 16th conference on business informatics,

Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270.

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.

Zhang, J., Cui, S., Xu, Y., Li, Q., & Li, T. (2018). A novel data-driven stock price trend prediction system. *Expert Systems with Applications*, 97, 60-69.

Zhang, Y., & Wu, L. (2009). Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network. *Expert Systems with Applications*, 36(5), 8849-8854.

Zhou, P.-Y., Chan, K. C., & Ou, C. X. (2018). Corporate communication network and stock price movements: insights from data mining. *IEEE Transactions on Computational Social Systems*, 5(2), 391-402.

#### COPYRIGHTS



This license allows others to download the works and share them with others as long as they credit them, but they can't change them in any way or use them commercially.

