

## Providing a Smart Trading System Based on the Combination of Technical Analysis Indicators, Meta-Heuristic Algorithms and Neural Network in Tehran Stock Exchange<sup>1</sup>

Fatemeh Asiaei Taheri<sup>2</sup>, Gholomreza Zomorodian<sup>3</sup>,  
Mirfiz Falah Shams<sup>4</sup>

Received: 2023/01/21  
Accepted: 2024/02/04

Research Paper

### Abstract

The main goal of investing in the stock market is to get the highest return at the desired time. Successful trading in financial markets should be done close to key reversal points.

In this research, we are trying to select the widely used technical rules by studying the previous researches and improving the decision parameters in the mentioned technical rules for each stock by using the firefly and gray wolf algorithm and converting contradictory signals issued from the optimized indicators to the unit. And finally, through the LSTM neural network, we will try to predict the entry and exit positions of the stock market.

This research was conducted from 1390 to September 1401 on Tehran Stock Exchange companies. The proposed model has been able to correctly identify buy, sell and hold points for a future trading day for long-term investors with an error of about thirty-six percent.

**Key Words:** Technical Indicators, Firefly Algorithm, GWO and LSTM.

**JEL Classification:** G17.

1. doi: 10.22034/JSE.2023.12263.2161
2. Instructor, Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. (taheri.fateme2012@gmail.com).
3. Associate Professor, Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. (Corresponding Author). (gh.zomorodian@gmail.com).
4. Associate Professor, Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. (fallahshams@gmail.com).



Copyright © 2024 The Authors. Published by Securities and Exchange Organization. This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license (<https://creativecommons.org/licenses/by-nc/4.0/>). Non-commercial uses of the work are permitted, provided the original work is properly cited.



سازمان بورس و اوراق بهادار، مرکز پژوهش، توسعه و مطالعات اسلامی

فصلنامه بورس اوراق بهادار، سال هفدهم، شماره ۶۵، بهار ۱۴۰۳، صص ۱۵۲-۱۳۳

## ارائه سیستم معاملاتی هوشمند مبتنی بر ترکیب شاخص های تحلیل تکنیکال، الگوریتم های فرا ابتکاری و شبکه عصبی در بورس اوراق بهادار تهران<sup>۱</sup>

فاطمه آسیائی طاهری<sup>۲</sup>، غلامرضا زمردیان<sup>۳</sup>، میرفیض فلاح شمس<sup>۴</sup>

تاریخ دریافت: ۱۴۰۲/۰۲/۰۲

تاریخ پذیرش: ۱۴۰۲/۰۹/۱۵

مقاله پژوهشی

### چکیده

هدف اصلی از سرمایه گذاری در بازار سهام، کسب بیشترین بازده در زمان مورد نظر می باشد. معاملات موفق در بازارهای مالی می بایست نزدیک به نقاط کلیدی کمینه و بیشینه نمودار قیمت انجام شود. در این پژوهش در تلاش هستیم تا با مطالعه پژوهشهای پیشین قواعد تکنیکی پر کاربرد را انتخاب و با بهره گیری از الگوریتم کرم شب تاب و گرگ خاکستری، متغیرهای تصمیم گیری در قواعد تکنیکی مذکور برای هر سهم، بهبود و نشانک های متناقض صادره از شاخص های بهینه شده را به نشانک واحد مبدل کنیم. در نهایت از طریق شبکه عصبی حافظه کوتاه مدت ماندگار سعی در پیش بینی موقعیت های ورود و خروج در بازار سهام را خواهیم داشت. این پژوهش از سال ۱۳۹۰ تا شهریور ۱۴۰۱ روی شرکت های بورس اوراق بهادار تهران انجام شده است. مدل پیشنهادی توانسته است با خطای حدود سی و شش درصد نقاط خرید، فروش و نگهداری را برای یک روز معاملاتی آتی برای سرمایه گذاران بلند مدت، به درستی شناسایی کند.

**واژه های کلیدی:** شاخص های فنی، الگوریتم کرم شب تاب، الگوریتم گرگ خاکستری و شبکه عصبی حافظه کوتاه مدت ماندگار.

طبقه بندی موضوعی: G17

doi: 10.22034/JSE.2023.12263.2161

۲. گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. (taheri.fateme2012@gmail.com)

۳. گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران و عضو گروه تحقیقاتی ریسک مالی مدرن. (نویسنده مسئول). (gh.zomorodian@gmail.com)

۴. گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. (fallahsahms@gmail.com)

حق انتشار این مستند، متعلق به نویسندگان آن است. © ۱۴۰۳. ناشر این مقاله، سازمان بورس و اوراق بهادار است. این مقاله تحت گواهی زیر منتشر شده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز است.



Creative Commons Attribution-NonCommercial 4.0 International license  
(https://creativecommons.org/licenses/by-nc/4.0/)

## مقدمه

پیش‌بینی قیمت آتی بازار سهام به منظور آگاهی از روند حرکت سهام و کاهش ریسک سرمایه‌گذاری، برای سرمایه‌گذاران بسیار مهم است. دانستن روند آتی بازار سهام به دلیل ماهیت بسیار نوسانی آن یک مسئله چالش برانگیز است. از این رو روش‌های محاسباتی مناسب برای پیش‌بینی حرکت قیمت سهم مورد نیاز است (بیک و کیم، ۲۰۱۸). در سال‌های اخیر به موازات پیشرفت‌های چشمگیر در پردازش سریع اطلاعات به وسیله ماشین‌های الکترونیکی، به کارگیری مدل‌های غیرخطی و روش‌های محاسبات نرم<sup>۱</sup> که به کارگیری محاسبات تقریبی<sup>۲</sup> برای حل مسائل است که حاصل آن راه‌حلی هر چند نادقیق اما قابل قبول برای حل مسائل محاسباتی پیچیده هستند که استفاده از آن در میان اقتصاددانان، به طور چشم‌گیری افزایش یافته است و در پی پیشرفت‌هایی که در زمینه رایانه و هوش مصنوعی و هم چنین کشف روابط آشوبی<sup>۳</sup> در سری‌های زمانی غیرخطی پدید آمد، فعالیت‌هایی در جهت پیش‌بینی روند سهام در کشورهای مختلف انجام شد. شبکه‌های عصبی از معروف‌ترین این مدل‌ها در حوزه پیش‌بینی متغیرهای اقتصادی است که استفاده از آن در دهه نود مورد توجه پژوهش‌گران قرار گرفته است. به طوری که امروزه پژوهشگران بسیاری به تحقیق در مورد کاربردهای محاسبات نرم در حوزه مالی می‌پردازند (بابا و همکاران، ۲۰۰۲).

در این راستا به منظور هوشمندسازی سیستم معاملات سهام تلاش‌های فراوانی شده است. سیستم معاملات سهام که به عنوان ابزاری کمکی در تصمیم‌گیری‌های سرمایه‌گذاری است، یکی از حوزه‌های پژوهشی روز دنیا به شمار می‌رود و افزون بر ظرفیت‌های پژوهشی از ظرفیت‌های خوبی در افزایش سودآوری برخوردار است. هدف یک سیستم معاملاتی انجام معاملاتی موفق است، معاملاتی که در محل تغییر جهت روند قیمت‌ها باید صورت پذیرند. سیستم‌های معاملاتی موجود شامل تحلیل فنی و بنیادی و مدل‌های ریاضی و یا ترکیب موارد یاد شده است.

تحلیل فنی کلاسیک که مبنای بسیاری از سیستم‌های معاملاتی است، بیشتر به صورت قوانین معامله‌گری مختلف ظاهر می‌شود و در بازارهای دنیا بسیار رایج است. استفاده از سیستم معاملاتی

- 
1. Soft Computing
  2. Approximate Calculations
  3. Chaos Theory

مبتنی بر تحلیل فنی دارای چندین محدودیت است که در این پژوهش به دنبال برطرف کردن این موارد هستیم. ابتدا اینکه استفاده از آن توسط عموم امکان پذیر نیست و نیازمند دانش و مهارت تخصصی است. متأسفانه اینگونه سیستم‌های معاملاتی به دلیل تعدد و تنوع قواعد فنی و به خاطر وابستگی به تجارب معامله‌گران در انتخاب آن‌ها، برای دریافت علائم ورود و خروج، موجب کاهش مطلوبیت آن‌ها نزد سرمایه‌گذاران شده است.

مسئله مهم این سیستم، عوامل بکارگیری شده در قواعد تکنیکی است که در صورت تعیین درست و هوشمندانه آن‌ها، نشانک‌های خرید و فروش مناسب برای کسب بیشترین بازده سرمایه‌گذاران در اختیار قرار می‌دهند. نکته چشمگیر در این خصوص آن است که در زمان بهینه‌سازی متغیرهای قواعد تکنیکی باید هزینه معاملات نیز در نظر گرفته شود. از محدودیت‌های دیگر آن می‌توان به این موضوع اشاره کرد که قواعد تکنیکی مختلف ممکن است نشانک‌های معاملاتی متناقضی را به طور همزمان ایجاد کنند که تصمیم‌گیری را در چنین شرایطی برای سرمایه‌گذار سخت می‌کند.

بنابراین با توجه به مشکلات و خلاءهای مطروحه در زمان بهره‌گیری سرمایه‌گذاران از تحلیل‌های سنتی، در این مطالعه سعی بر آنست تا با مطالعه پژوهش‌های پیشین قواعد تکنیکی پر کاربرد را انتخاب و با بهره‌گیری از الگوریتم کرم شب‌تاب در وهله اول متغیرهای تصمیم‌گیری در قواعد تکنیکی یادشده برای هر سهم، بهبود داده شود و این قواعد مبنای پیش‌بینی و شناسایی نشانک‌های خرید و فروش قرار گیرد. سپس با بهره‌گیری از الگوریتم گرگ خاکستری نشانک‌های متناقض را به نشانک واحد مبدل می‌کنیم و در نهایت از طریق شبکه عصبی حافظه کوتاه مدت ماندگار سعی به پیش‌بینی موقعیت‌های ورود و خروج در بازار سهام را خواهیم داشت.

### مبانی نظری و مروری بر پیشینه پژوهش

همواره سرمایه‌گذاری در بازار سرمایه به عنوان راهی برای کسب درآمد، از اهمیت خاصی نزد سرمایه‌گذاران برخوردار بوده است. از این رو سرمایه‌گذاران به ایجاد و توسعه تحلیل‌ها و روش‌های مختلفی به منظور پیش‌بینی و افزایش بازدهی حاصل از سرمایه‌گذاری‌های خود پرداخته‌اند. به همین دلیل نیاز به توسعه سیستم‌های معاملاتی در بازار سرمایه ضروری است، که ضمن داشتن دقت بالا در پیش‌بینی‌ها، بازده حاصل از سرمایه‌گذاری را افزایش داده و ریسک

سرمایه‌گذاری را تا حد ممکن کاهش دهد. این ضرورت ما را بر آن داشت که سیستم معاملاتی بر پایه تحلیل فنی و بهینه‌سازی آن از طیف الگوریتم کرم شب تاب و گرگ خاکستری ایجاد کنیم.

تحلیل فنی مطالعه رفتارهای بازار با استفاده از نمودارها و با هدف پیش‌بینی آینده روند قیمت‌ها است. تحلیل فنی بر پایه سه اصل استوار است: همه چیز در قیمت منظور شده که به عنوان مهمترین اصل است، اصل دوم: قیمت‌ها دوست دارند روند فعلی خود را حفظ کنند به جای آنکه تغییر جهت بدهند و اصل سوم که می‌گوید تاریخ تکرار می‌شود. اصول مطرح در تحلیل فنی، راهبردهای سرمایه‌گذاری متعددی را شامل می‌شود و پژوهش‌های زیادی در خصوص آن راهبردها صورت گرفته است (محسن رضوانی اقدم، ۱۳۹۵).

الگوریتم کرم شب تاب که به اختصار FA نمایش داده می‌شود از روش‌های بهینه‌سازی مبتنی بر الگوهای فراابتکاری است که در اواخر سال ۲۰۰۷ و توسط ژین شی - یانگ معرفی شده است، که ایده اصلی آن از ارتباط نوری میان کرم‌های شب تاب الهام گرفته شده است. این الگوریتم را می‌توان از مظاهر هوش ازدحامی دانست، که در آن از همکاری اعضای ساده و کم‌هوش، مرتبه بالاتری از هوشمندی ایجاد می‌شود که به طور حتم توسط هیچ یک از اجزا قابل حصول نیست. الگوریتم کرم شب تاب یک الگوریتم فراکتشافی، با الهام از رفتارهای کرم شب تاب مصنوعی است، که فرایند آن به شرح زیر است:

۱. همه کرم‌های شب تاب تمایل جنسی دارند، به طوری که یک کرم شب تاب تمام کرم‌های شب تاب دیگر را جذب می‌کند.
  ۲. جذابیت هر کرم شب تاب متناسب است با روشنایی آن، و هر کرم شب تاب به کرم شب تاب پر نورتر جذب خواهد شد (به سمت آن حرکت می‌کند) باید این نکته را در نظر داشت که فاصله کرم‌های شب تاب از یکدیگر در جذابیت آن‌ها موثر است.
  ۳. کرم‌های شب تاب بصورت تصادفی به سمت کرم‌های پر نورتر حرکت می‌کنند.
- الگوریتم کرم شب تاب با مدلسازی رفتار مجموعه‌ای از کرم‌های شب تاب و تخصیص مقداری مرتبط با برازندگی مکان هر کرم شب تاب به عنوان مدلی برای یافتن نقاط پر نورتر و به روز کردن مکان کرم‌ها در تکرارهای متوالی الگوریتم، به جستجوی جواب بهینه مسئله می‌پردازند. در واقع دو مرحله اصلی الگوریتم در هر تکرار، فاز به روز کردن نقاط پر نورتر و فاز حرکت هستند. بدین ترتیب کرم‌های شب تاب به سمت کرم‌های شب تاب دیگر با نور بیشتر

که در همسایگی آنها باشند حرکت می کنند. بنابراین طی تکرارهای متوالی مجموعه به سمت جواب بهتر متمایل می شود.

الگوریتم بهینه سازی گرگ خاکستری یکی از جدیدترین الگوریتم های فراابتکاری به شمار می رود، میرجیلی و همکارانش (۲۰۱۴) الگوریتم گرگ خاکستری در گروه الگوریتم های هوش جمعی قرار دارد و یک الگوریتم فراابتکاری<sup>۱</sup> و مانند خیلی از الگوریتم های فراابتکاری دیگر، الهام گرفته از طبیعت است و اساس آن ساختار سلسله مراتبی است که رفتار اجتماعی گرگ های خاکستری را در زمان شکار، مدل سازی می کند. این الگوریتم مبتنی بر جمعیت بوده، فرآیند ساده ای دارد و به سادگی قابلیت تعمیم به مسائل با ابعاد بزرگ را دارد. گرگ های خاکستری به عنوان شکارچیان راس در نظر گرفته می شوند، که در بالای هرم زنجیره غذایی هستند. گرگ های خاکستری ترجیح می دهند در یک گروه (دسته) زندگی کنند، که هر گروه به طور متوسط دارای ۵-۱۲ عضو است. همچنین در هر گله از گرگ ها برای شکار کردن شامل ۴ درجه هستند.

شبکه های عصبی حافظه کوتاه مدت ماندگار، نسخه ای از شبکه های بازگشتی هستند که حافظه در آنها گسترش داده شده است. شبکه های بازگشتی، قدرتمند و قوی هستند و به دلیل این که حافظه داخلی دارند، می توان آنها را امیدوارکننده ترین الگوریتم های مورد استفاده دانست. شبکه های عصبی بازگشتی مانند بسیاری از الگوریتم های یادگیری عمیق دیگر، قدیمی تر هستند. آنها ابتدا در دهه ۱۹۸۰ ایجاد گردیدند اما ظرفیت واقعی آنها را در سال های اخیر مشاهده شده است. افزایش قدرت محاسباتی همراه با حجم انبوه داده ای که اکنون باید با آن کار کنیم و ابداع شبکه عصبی حافظه کوتاه مدت ماندگار<sup>۲</sup> در دهه ۱۹۹۰، باعث شده که شبکه های بازگشتی<sup>۳</sup> به شبکه هایی پیشگام تبدیل شوند.

موفقیت در بازار سرمایه وابسته به تشخیص به موقع زمان خرید و فروش سهام است. هرچه تشخیص و پیش بینی این زمان دقیق تر باشد، می توان انتظار داشت که سود حاصل از سرمایه گذاری بر روی سهام افزایش و ریسک حاصل از این سرمایه گذاری کاهش یابد. در گذشته سرمایه گذاران در بیشتر موارد با استفاده از تحلیل ها و مجموعه قوانین بنیادی و یا فنی

---

1. Metaheuristic  
2. Long Short-Term Memory (LSTM)  
3. RNN

زمان شروع یک روند جدید را پیش‌بینی می‌کردند (تاناکا، ۲۰۰۷). اما در چندین سال اخیر پژوهش‌هایی با هدف استفاده از هوش مصنوعی به منظور ایجاد و توسعه سیستم‌های معاملاتی صورت گرفته است، به طور مثال برازیلیرو<sup>۱</sup> (۲۰۱۳) با استفاده از قاعده و قوانین تحلیل فنی و شبکه‌های عصبی، الگوریتمی طراحی کرد که به نتایج قابل قبول و مطلوبی دست یافت. ژینجی<sup>۲</sup> و همکاران (۲۰۱۴) در مقاله‌ای تحت عنوان «پیش‌بینی روند سهام با شاخص‌های فنی با استفاده از ماشین بردار پشتیبان» به بررسی شاخص‌های فنی مختلف از جمله RSI، در تعادل دوره، ویلیامز %R و غیره ... به عنوان ویژگی‌های انتخاب شده، در سهام سه شرکت (اپل<sup>۳</sup>، مایکروسافت<sup>۴</sup> و آمازون<sup>۵</sup>) در دوره‌های زمانی ۲۰۱۰ تا ۲۰۱۴ پرداختند که از بین ۸۴ مورد ویژگی، یک درخت بسیار تصادفی اجرا شد و سپس از ماشین بردار پشتیبان، داده‌های آموزشی تغذیه شدند.

مسکیتا و همکاران (۲۰۲۰) به بررسی ترکیب شبکه عصبی حافظه کوتاه‌مدت ماندگار با آزمون واریانس به منظور پیش‌بینی روند قیمت در بازار سهام برزیل پرداختند که نتایج بدست آمده نشان می‌دهد، شبکه عصبی حافظه کوتاه‌مدت ماندگار عملکرد بهتری در پیش‌بینی قیمت‌ها از سایر الگوریتم‌ها داشته است. افزون بر این، در صورتی که داده قیمتی مورد بررسی بیشتر از ۲۰۰۰ روز باشد، عملکرد این الگوریتم اختلاف معناداری از سایر الگوریتم‌ها پیدا می‌کند.

هو و همکاران (۲۰۲۱) به پیش‌بینی قیمت سهام شرکت‌های اپل، آمازون، ای بی ام<sup>۶</sup>، مایکروسافت در بازه سال‌های ۲۰۱۸ تا ۲۰۱۹ با استفاده از شبکه‌های عصبی بازگشتی، حافظه کوتاه مدت ماندگار و حافظه کوتاه مدت ماندگار با لایه‌های کانولوشنی پرداختند که ۶۰٪ داده‌های برای آموزش، ۲۰٪ برای تایید آموزش و ۲۰٪ برای آزمون مورد استفاده قرار گرفت. نتایج پژوهش نشان می‌دهد که خطای پیش‌بینی در مدل حافظه کوتاه مدت ماندگار با لایه کانولوشنی، کمترین میزان خطا در بین مدل‌ها را داشته است.

1. Brasileiro
2. Xinjie
3. APPLE
4. MICROSOFT
5. AMZN
6. IBM

فان ژانگ و همکاران (۲۰۲۲) در مقاله خود تحت عنوان پیش‌بینی شاخص بورس بر اساس شبکه عصبی پس انتشار خطا و الگوریتم بهینه‌سازی جستجوی گنجشک (ISSA-BP)، عملکرد مدل پیشنهادی را در چهار مجموعه داده، که SSE، SZSE، SP500 و DJI هستند، ارزیابی می‌کند. در این مقاله از دو نوع مدل، الف- الگوریتم های بهینه‌سازی هوش ازدحامی که برای بهینه‌سازی BPNN است و شامل GA-BP، PSO-BP، ACO-BP، CS-BP، GWO-BP و SSA-BP و ب- از چند مدل یادگیری عمیق، برای مقایسه با حالت پیشنهادی استفاده شده است. نتایج تجربی نشان می‌دهد که مدل ISSA-BP به موفقیت بزرگی در پیش‌بینی کوتاه‌مدت قیمت سهام دست می‌یابد، که می‌تواند به سرمایه‌گذاران در پیش‌بینی روند بازار و یافتن زمان مناسب برای معامله کمک کند.

#### جدول ۱. سایر مطالعات انجام شده مهم پیرامون کاربرد شبکه عصبی در حوزه مالی

پژوهشگر	سال	موضوع پژوهش
فان ژانگ و همکاران	۲۰۲۲	در مقاله‌ای تحت عنوان پیش‌بینی شاخص بورس بر اساس شبکه عصبی پس انتشار خطا و الگوریتم بهینه‌سازی جستجوی گنجشک، عملکرد مدل پیشنهادی را در چهار مجموعه داده، که SSE، SZSE، SP500 و DJI هستند، ارزیابی می‌کند.
بودی هارتو	۲۰۲۱	به پیش‌بینی قیمت سهام بانک‌های منطقه آسیای مرکزی با استفاده از شبکه عصبی حافظه کوتاه مدت ماندگار پرداخته‌است.
هانو و جیانگ	۲۰۲۰	با ارائه مدل ترکیبی شبکه عصبی بازگشتی و حافظه کوتاه مدت ماندگار به پیش‌بینی قیمت سهام در تایم فریم‌های مختلف نمودند.
گائو و همکارانش	۲۰۲۰	به مقایسه قدرت انواع مدل‌های LSTM، MLP، CNN در خصوص پیش‌بینی شاخص‌های SP500 و Nikkei225 در افق زمانی یک روزه پرداخته‌اند.
کیم	۲۰۱۹	مدلی برای پیش‌بینی قیمت سهام در S&P500 با استفاده از شبکه‌های عصبی بازگشتی و حافظه کوتاه مدت ماندگار ارائه نمود.
مریم سهرابی و همکاران	۱۴۰۱	به پیش‌بینی جهش شاخص بازار سهام براساس رویکرد شبکه عصبی بازگشتی یادگیری عمیق پرداخته‌اند
ناهید مالکی‌نیا و همکاران	۱۴۰۱	به بررسی پیش‌بینی مدیریت سود با روش ترکیبی شبکه عصبی پرسپترون چندلایه و الگوریتم‌های فراابتکاری پرداخته‌اند.
شریف‌فر و همکاران	۱۴۰۰	در پژوهشی معماری‌های الگوریتم حافظه کوتاه‌مدت ماندگار جهت پیش‌بینی قیمت سهام مورد بررسی قرار دادند.



پژوهشگر	سال	موضوع پژوهش
ذوالفقاری و همکاران	۱۳۹۹	به معرفی یک مدل ترکیبی از شبکه یادگیری عمیق و مدل‌های منتخب خانواده GARCH جهت پیش‌بینی کوتاه‌مدت بازدهی روزانه شاخص کل بورس اوراق بهادار تهران پرداخته‌اند.
باباجانی	۱۳۹۸	مدلی جهت پیش‌بینی قیمت سهام در بورس تهران با استفاده از شبکه عصبی بازگشتی بهینه شده با الگوریتم کلونی زنبور عسل مصنوعی در بورس تهران ارائه نمود.

منبع: پژوهش‌های پیشین

راهبردهای معاملاتی استفاده در این پژوهش به شرح زیر است:

۱. راهبرد خرید و نگهداری: در این راهبرد سرمایه‌گذار در ابتدای دوره سهم مورد نظر را خریداری کرده و تا پایان دوره آن نگهداری می‌کند.
۲. راهبرد خرید و فروش مبتنی بر متغیرهای انگاره: در این راهبرد سرمایه‌گذار با متغیرهای انگاره که برای هر شاخص تعریف شده، اقدام به خرید و فروش می‌کند.
۳. راهبرد خرید و فروش مبتنی بر متغیرهای بهینه شده: در این راهبرد سرمایه‌گذار با متغیرهای بهینه شده با استفاده از الگوریتم کرم شب تاب که برای هر شاخص محاسبه می‌شود، اقدام به خرید و فروش می‌کند.

### پرسش‌های پژوهش

۱. امکان طراحی مدلی مبتنی بر روش تحلیل فنی با رویکرد ترکیبی الگوریتم‌های فراابتکاری و شبکه عصبی برای پیش‌بینی نقاط ورود و خروج به موقع برای یک روز معاملاتی آتی در بورس اوراق بهادار تهران برای سرمایه‌گذاران بلندمدت وجود دارد؟
۲. کدام معماری شبکه عصبی حافظه کوتاه مدت ماندگار<sup>۱</sup> عملکرد بهتری در پیش‌بینی نقاط ورود و خروج برای یک روز معاملاتی آتی در بورس اوراق بهادار تهران دارد؟

### روش‌شناسی پژوهش

در این بخش از مقاله، ابتدا ساز و کار الگوریتم کرم شب‌تاب بررسی و با استفاده از آن اقدام به بهینه‌سازی متغیرهای شاخص‌های فنی برای هر یک از شرکت‌های منتخب از بورس اوراق بهادار تهران می‌پردازیم. در این پژوهش، شاخص‌های مورد بررسی بر اساس درصد موفقیت آن‌ها در مطالعات پیشین انتخاب شده‌اند و شامل شاخص‌های میانگین متحرک، میانگین متحرک نمایی، شاخص میانگین متحرک همگرایی و اگرایی<sup>۱</sup>، استوکاستیک<sup>۲</sup>، شاخص قدرت نسبی<sup>۳</sup>، میانگین شاخص جهت دار<sup>۴</sup>، آرون<sup>۵</sup>، ویلیامز<sup>۶</sup>، باند بولینگ<sup>۷</sup> و نوسانگر فشار حرکت قیمت و معاملاتی<sup>۸</sup> هستند.

### الگوریتم کرم شب‌تاب

با توجه به رویکرد الگوریتم کرم شب‌تاب به منظور یافتن جواب بهینه، طریقه استفاده از این الگوریتم در حل مسأله پژوهش حاضر بدین شکل است که تابع هدف در این بهینه‌سازی، سود و زیان نهایی ناشی از خرید و فروش به ازای هر شاخص و سهم بوده و متغیرهای این مسئله نیز متغیرهای شاخص‌های فنی مورد بررسی است. در این مسئله از جمعیت ۵۰ و تعداد ۲۰۰ تکرار استفاده شده است، این بدین منظور است که با جمعیت ۵۰ فرآیند ۲۰۰ مرتبه برای هر سهم منتخب و هر شاخص به صورت جداگانه اجرا خواهد شد، تا بیشترین مقدار بازده حاصل از خرید و فروش انجام شده بر اساس نشانک‌های صادره با بیشترین ضریب اطمینان، محاسبه شود. در این مرحله علاوه بر محاسبه مقدار بیشترین بازده، متغیرهای هر شاخص بهینه شده نیز مشخص می‌شود.

### الگوریتم گرگ خاکستری

در این مرحله بازده حاصل از هر دوازده شاخص بهینه شده توسط الگوریتم کرم شب‌تاب برای هر سهم، به عنوان ورودی الگوریتم گرگ خاکستری استفاده می‌شود و این الگوریتم

1. Moving Average Convergence Divergence
2. Stochastic
3. RSI(Relative Strength Index)
4. ADX(Average Directional movement Index)
5. Aroon
6. Williams
7. Bollinger Band
8. MFI(Money Flow Index)

به دنبال آن است که با توجه به بازده‌های حاصل شده، وزن مناسب به هر شاخص تخصیص دهد به گونه‌ای که مجموع وزن‌های تخصیص داده شده، برابر با یک باشد و بازده کل حاصل از وزن‌های تخصیص داده شده، به بیشترین میزان ممکن برسد. با این فرآیند، نشانک‌های دریافت شده از دوازده شاخص مورد بررسی به یک نشانک واحد تبدیل خواهد شد.

تابع هدف در این الگوریتم، بیشینه‌سازی بازده حاصل از مجموع نشانک‌های صادره از دوازده شاخص مورد بررسی به ازاء هر سهم، با تخصیص مناسب وزن است که متغیرهای این مرحله نیز وزن‌های تخصیص داده شده به شاخص‌های فنی بوده و برای کسب بیشترین ضریب اطمینان، از جمعیت ۵۰ و تعداد ۲۰۰ تکرار استفاده شده است.

### تعریف برجسب‌ها

در این مقطع می‌بایست نقاط نشانک خرید و فروش را برای تعریف در شبکه عصبی شناسایی کنیم. در این راستا دنبال آن هستیم که به هر روز معاملاتی برای هر سهم یک برجسب تخصیص دهیم، این برجسب‌ها شامل: نگهداری، خرید و فروش است.

برای تعریف برجسب‌های یادشده از شاخص زیگزاگ استفاده کردیم، این شاخص نقاط مرزی را با توجه به متغیر انحراف، مشخص می‌کند. در این پژوهش محاسبات شاخص زیگزاگ با انحراف ۲۰ انجام شد که برای سرمایه‌گذاران بلندمدت مناسب است، در این راهبرد هدف سرمایه‌گذار نوسان گرفتن در بازه‌های کوتاه مدت نیست و تعداد معاملات آن نیز کمتر است.



شکل ۱. نمایش عملکرد شاخص زیگزاگ

منبع: نمودار قیمتی در بورس اوراق بهادار تهران

### شبکه‌های عصبی

شبکه‌های عصبی در بیشتر موارد با وزن‌های تصادفی شروع می‌شوند، اما سپس خود را بارها و بارها آموزش می‌دهند تا به حداکثر عملکرد برسند. شبکه عصبی با آزمون و خطا سعی می‌کند مقادیر بهینه را پیدا کند. یک روش بهینه‌سازی وزن‌ها در شبکه عصبی استفاده از شبکه عصبی بازگشتی<sup>۱</sup> است. به این صورت که یک بار داده‌ها از لایه ورودی تا لایه خروجی حرکت می‌کنند. سپس همان مسیر به صورت برعکس طی می‌شود و در هر مرحله وزن‌ها و بایاس‌ها بهینه می‌شوند.

### شبکه عصبی حافظه کوتاه مدت ماندگار

در این پژوهش از شبکه عصبی حافظه کوتاه مدت ماندگار با تکرار<sup>۲</sup> برابر با ۶۰ که جز شبکه‌های عصبی بازگشتی محسوب می‌شود، استفاده شده است. شبکه پیشنهادی شامل دولایه کانولوشنی<sup>۳</sup> با تعداد نرون‌های ۱۲۸ و ۲۵۶، تکرار<sup>۴</sup> برابر با ۲۰۰ و اندازه دسته<sup>۵</sup> برابر با ۳۲ می‌باشد. با توجه به مطالعات پیشین دریافتیم که افزودن لایه بیشتر در شبکه عصبی حافظه کوتاه مدت ماندگار موجب افزایش هزینه زمان محاسبات و همچنین موجب بیش برآزش در این شبکه نیز شده است. از طرفی دیگر تغییر معناداری در دقت شناسایی نشانک‌های خرید و فروش ندارد. به منظور رفع خطای بیش برآزش نیز از دراپ اوت استفاده شد که این کار می‌تواند به از بین بردن بیش برآزش<sup>۶</sup> کمک کند. در این شیوه درصد مشخصی از واحدها به صورت تصادفی از لایه‌های مخفی حذف می‌شود. این کار به از بین بردن وابستگی‌های نادر در داده‌های آموزشی کمک می‌کند (پارش چهاحجر و مانا، ۲۰۲۲).

در این بخش به منظور پاسخ به پرسش‌های پژوهش از نرم افزار پایتون برای توصیف داده‌های استفاده شد. بدین ترتیب داده‌های ورودی را که از شرکت‌های منتخب در بورس اوراق بهادار تهران استخراج شده است، به دو گروه کلی تقسیم می‌کنیم: الف- گروهی برای آموزش مدل (دوره زمانی را برای آموزش در نظر می‌گیریم که شامل تمامی سیکل‌های بازار سرمایه (دوره رونق و دوره رکود بازار) باشد، تا سیستم معاملاتی در تمامی دوران آموزش داده شود).

1. RNN(Recurrent Neural Network)
2. Sequence Length
3. Convolution
4. Epochs
5. Batch size
6. Over fitting

و ب- گروه دیگر برای آزمون آن. داده‌هایی که برای دو گروه بیان شده مورد استفاده قرار می‌گیرد به شرح زیر است::

آخرین قیمت سهام تعدیل شده، حجم معاملات، تعداد دفعات معامله سهم در یک روز، مبلغ معامله شده در روز، تعداد سهام معامله شده در روز، در بازه زمانی مورد نظر و شاخص‌های یادشده است.

به‌طور تقریبی ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای آزمون استفاده شده است. فرآیند مدل ارائه شده را می‌توان به پنج گام زیر تقسیم کرد:

۱. جمع آوری داده‌ها و تقسیم آن به دو گروه آموزش و آزمون؛
۲. انتخاب بهترین مجموعه متغیرها برای هر شاخص بصورت مجزا با در نظر گرفتن قواعد معاملاتی هر شاخص به ازای هر سهم، از طریق الگوریتم کرم شب تاب؛
۳. رفع نشانک‌های متناقض صادر شده از قواعد فنی (یافتن بهترین وزن برای هر شاخص بهینه شده) از طریق الگوریتم گرگ خاکستری؛
۴. تعریف برجسب‌های خرید، فروش و نگهداری با استفاده از شاخص زیگزاگ؛
۵. پیش‌بینی موقعیت‌های ورود و خروج برای یک روز معاملاتی آتی توسط شبکه عصبی حافظه کوتاه مدت ماندگار با استفاده از خروجی مراحل چهار و پنج.

### داده‌های پژوهش

جامعه آماری مورد نظر این پژوهش کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است که از فروردین ۱۳۹۰ تا شهریور ۱۴۰۱ قابل معامله بوده‌اند و افزون بر این به منظور کاهش ریسک نقدشوندگی سرمایه‌گذاران، سهامی که در هر سال کمتر از ۱۵۰ روز معاملاتی داشته‌اند، از جامعه آماری حذف شده‌اند. که در نهایت ۱۱۷ سهم به‌عنوان نمونه مورد بررسی قرار گرفت. جدول ۲ بازه زمانی انتخاب شده برای استخراج داده‌های آموزش و آزمون را نمایش می‌دهد.

جدول ۲. (بازه زمانی انتخاب شده)

بازه زمانی مورد بررسی	بازه زمانی آموزش	بازه زمانی آزمون
تاریخ شروع	۱۳۹۰-۰۱-۰۱	۱۳۹۸-۰۱-۰۱
تاریخ خاتمه	۱۳۹۷-۱۲-۲۹	۱۴۰۱-۰۶-۰۱

منبع: داده‌های قیمتی سهام پذیرفته شده در بورس اوراق بهادار

## یافته‌های پژوهش

الگوریتم و سیستم معاملاتی معرفی شده در این پژوهش، بر روی داده‌های قیمتی شرکت‌های منتخب بازار سرمایه ایران پیاده سازی و همچنین از قیمت تعدیل شده به منظور محاسبه شاخص‌های فنی استفاده شد. شایان بیان است کارمزد خرید و فروش را نیز در نظر گرفتیم.

## نتیجه آزمون بررسی عملکرد راهبردها اول و سوم:

مقایسه بازده کسب شده راهبرد خرید و نگهداری با راهبرد خرید و فروش مبتنی بر متغیرهای بهینه شده با الگوریتم کرم شب تاب در جدول ۳ نشان می‌دهیم.

## جدول ۳. بررسی آزمون T در سطح اطمینان ۹۹ درصد بین راهبرد خرید و نگهداری و راهبرد خرید و فروش با متغیرهای بهینه شده

مقایسه راهبرد خرید و نگهداری با متغیرهای بهینه شده شاخص‌ها توسط الگوریتم کرم شب تاب	مقایسه دو به دو				T	درجه آزادی	تابع علامت	
	میانگین	انحراف معیار	انحراف معیار از میانگین	در سطح اطمینان ۹۹٪				
				کمترین مقدار				بیشترین مقدار
خرید و نگهداری با شاخص بهینه شده مک دی	۱۸۶/۱۲۲۷۲	۱۴۲/۳۹۶۸۹	۱۳/۱۶۴۶۰	۱۶۰/۰۴۸۵۷	۲۱۲/۱۹۶۸۶	۱۴/۱۳۸	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده میانگین متحرک ساده	۳۵۸/۳۶۰۴۲	۲۳۵/۱۹۵۴۰	۲۱/۷۵۳۰۷	۳۱۵/۲۷۵۷۳	۴۰۱/۴۴۵۱۱	۱۶/۴۷۴	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده آرون	۱۸۲/۵۰۵۸۹	۱۲۷/۹۱۶۲۷	۱۱/۸۲۵۸۶	۱۵۹/۰۸۳۲۸	۲۰۵/۹۲۸۵۰	۱۵/۴۳۳	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص قدرت نسبی	۳۶۵/۵۵۷۶۸	۲۶۰/۰۱۰۶۶	۲۴/۰۳۷۹۹	۳۱۷/۹۶۷۴۱	۴۱۳/۱۹۷۹۶	۱۵/۲۰۷	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده میانگین جهت دار	۱۸۰/۷۳۳۹۲	۱۳۰/۵۸۶۶۱	۱۲/۰۷۲۷۴	۱۵۶/۸۶۲۳۵	۲۰۴/۶۸۵۵۰	۱۴/۹۷۴	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص استوک استیک	۲۱۲/۰۴۲۹۸	۱۵۵/۲۷۶۶۲	۱۴/۳۶۴۵۷	۱۸۳/۵۹۲۱۳	۲۴۰/۴۹۳۸۳	۱۴/۷۶۲	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص میانگین متحرک نمایی	۳۵۵/۲۴۶۳۳	۲۴۳/۹۲۴۹۴	۲۲/۵۵۰۸۷	۳۱۰/۵۸۱۳۹	۳۹۹/۹۱۱۰۷	۱۵/۷۵۳	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص ویلامز	۲۰۸/۱۵۸۷۱	۱۶۳/۶۳۴۴۲	۱۵/۱۲۸۰۱	۱۷۷/۱۹۵۷۸	۲۳۸/۱۲۱۶۳	۱۳/۷۶۰	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص باند بولینگر	۳۵۳/۸۷۲۹۰	۲۳۷/۰۵۴۱۲	۲۱/۹۱۵۶۶	۳۱۰/۴۶۶۱۷	۳۹۷/۲۷۹۶۳	۱۶/۱۴۷	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص نوسانگر مبتنی بر فشار حرکت	۲۲۰/۴۴۳۸۴	۱۵۰/۱۳۳۴۳	۱۳/۸۷۹۸۴	۱۹۲/۹۵۳۰۶	۲۴۷/۹۳۴۶۱	۱۵/۸۸۲	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص کانال کالا	۲۲۱/۸۶۰۴۲	۱۶۳/۸۱۰۲۱	۱۵/۱۵۰۷۳	۱۹۱/۸۵۲۴۹	۲۵۱/۸۶۳۳۵	۱۴/۶۴۴	۱۱۶	/۰۰۰
خرید و نگهداری با شاخص بهینه شده شاخص جریان نقدینگی	۲۴۳/۸۱۰۲	۱۶۷/۱۶۲۲۴	۱۵/۴۵۴۱۵	۲۱۳/۲۷۲۱۲	۲۷۴/۴۸۹۹۲	۱۵/۷۸۱	۱۱۶	/۰۰۰

منبع: یافته‌های پژوهش

در جدول (۳) حد بالا و پایین، انحراف معیار، خطای استاندارد انحراف معیار و آزمون T در سطح اطمینان ۹۹٪ به ازای ۱۲ شاخص منتخب و راهبرد خرید و نگهداری محاسبه شده است، که با توجه به کوچک‌تر بودن مقدار تابع علامت از مقدار خطا، نشان دهنده آن است عملکرد راهبرد خرید و فروش براساس متغیرهای بهینه شده، بهتر از راهبرد خرید و نگهداری است.

#### نتیجه آزمون بررسی عملکرد راهبردهای دوم و سوم:

مقایسه بازده کسب شده راهبرد خرید و فروش با متغیرهای انگاره و راهبرد خرید و فروش مبتنی بر متغیرهای بهینه شده با الگوریتم کرم شب تاب در جدول ۴ است.

جدول ۴

آزمون مقایسه T به ازای دو متغیر									
مقایسه راهبرد خرید و نگهداری با متغیرهای بهینه شده شاخص‌ها توسط الگوریتم کرم شب تاب	مقایسه دو به دو					T	درجه آزادی	تابع علامت	
	میانگین	انحراف معیار	انحراف معیار از میانگین	در سطح اطمینان ۹۹٪					
				بیشترین مقدار	کمترین مقدار				
شاخص مک دی	۱۹۱/۱۷۱۹۳	۲۲۵/۷۷۳۸۲	۲۰/۸۷۲۸۰	۱۴۹/۸۳۰۷۳	۲۳۲/۵۱۳۱۴	۹/۱۵۹	۱۱۶	/۰۰۰	
شاخص میانگین متحرک ساده	۲۲۹/۷۷۷۵۲	۱۷۶/۴۲۰۴۶	۱۶/۳۱۰۰۸	۱۹۷/۴۷۳۳۶	۲۶۲/۰۸۱۶۸	۱۴/۰۸۸	۱۱۶	/۰۰۰	
شاخص آرون	۱۹۵/۲۹۶۹۲	۱۷۸/۴۴۱۸۸	۱۶/۴۹۶۹۶	۱۶۲/۶۲۲۶۲	۲۲۷/۹۷۱۲۳	۱۱/۸۳۸	۱۱۶	/۰۰۰	
شاخص قدرت نسبی	۲۳۸/۸۶۸۸۹	۱۸۵/۹۶۲۷۱	۱۷/۱۹۲۲۶	۲۰۴/۸۱۷۴۵	۲۷۲/۹۲۰۳۲	۱۳/۸۹۴	۱۱۶	/۰۰۰	
شاخص میانگین جهت دار	۱۲۶/۷۸۳۱۶	۱۰۹/۲۶۸۸۴	۱۰/۱۰۱۹۱	۱۰۶/۷۷۵۰۶	۱۴۶/۷۹۱۲۶	۱۲/۵۵۰	۱۱۶	/۰۰۰	
شاخص استوک استیک	۱۸۲/۹۷۹۳۲	۱۴۴/۴۱۲۵۶	۱۳/۳۵۰۹۵	۱۵۶/۵۳۶۰۹	۲۰۹/۴۲۲۵۵	۱۳/۷۰۵	۱۱۶	/۰۰۰	
شاخص میانگین متحرک نمایی	۲۲۰/۸۸۲۱۴	۱۵۷/۹۳۳۴۲	۱۴/۶۰۰۹۵	۱۹۱/۹۶۳۱۲	۲۴۹/۸۰۱۱۶	۱۵/۱۲۸	۱۱۶	/۰۰۰	
شاخص ویلیامز	۹۹/۳۲۴۲۷	۱۰۶/۹۴۹۶۳	۹/۸۸۷۵۰	۷۹/۷۴۰۸۴	۱۱۸/۹۰۷۷۱	۱۰/۰۴۵	۱۱۶	/۰۰۰	
شاخص باند پولینگر	۲۲۷/۱۳۸۳۸	۱۷۱/۱۵۹۵۹	۱۵/۸۳۳۷۱	۱۹۵/۷۹۷۵۳	۲۵۸/۴۷۹۲۳	۱۴/۳۵۴	۱۱۶	/۰۰۰	
شاخص نوسانگر مبتنی بر فشار حرکت	۹۲/۲۴۳۰۸	۱۲۵/۷۰۵۵۹	۱۱/۶۲۱۴۹	۶۹/۲۲۵۲۶	۱۱۵/۲۶۰۸۹	۷/۹۳۷	۱۱۶	/۰۰۰	
شاخص کانال کالا	۸۱/۴۴۵۹۸	۱۱۹/۶۵۴۹۸	۱۱/۰۶۲۱۱	۵۹/۵۳۶۰۹	۱۰۳/۳۵۵۸۸	۷/۳۶۳	۱۱۶	/۰۰۰	
شاخص جریان نقدینگی	۱۲۰/۳۸۹۴۹	۱۳۶/۰۰۰۴۹	۱۲/۵۷۳۲۵	۹۵/۴۸۶۵۸	۱۴۵/۲۹۲۳۹	۹/۵۷۵	۱۱۶	/۰۰۰	

منبع: یافته‌های پژوهش

در جدول ۴ حد بالا و پایین، انحراف معیار، خطای استاندارد انحراف معیار و آزمون T در سطح اطمینان ۹۹٪ به ازای ۱۲ شاخص منتخب و راهبرد خرید و فروش مبتنی بر متغیرهای انگاره

محاسبه شده است، که با توجه به کوچک تر بودن مقدار تابع علامت از مقدار خطا، نشان دهنده آن است نشان دهنده آن است عملکرد راهبرد خرید و فروش براساس متغیرهای بهینه شده، بهتر از راهبرد خرید و فروش مبتنی بر متغیرهای انگاره است.

### ارزیابی عملکرد شبکه عصبی پیشنهادی

برای بررسی عملکرد مدل ارائه شده، پس از عملکرد معماری‌های مطرح شده، میزان خطا مقادیر پیش‌بینی شده نسب به مقادیر واقعی با استفاده از درصد قدرمطلق میانگین خطا<sup>۱</sup> و مجذور میانگین مربعات خطا<sup>۲</sup> محاسبه خواهد شد، تا مناسب ترین معماری براساس میزان کمترین خطای پیش‌بینی، انتخاب شود. مدل‌های محاسبه خطا به صورت زیر نمایش داده می‌شود.

$$RSME = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - x_i)^2} \quad \text{رابطه ۱}$$

$$MAPE = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{y_i - x_i}{y_i} \right| \quad \text{رابطه ۲}$$

رابطه ۱، مجذور میانگین مربعات خطا و رابطه ۲، درصد قدرمطلق میانگین خطا می‌باشد که در آن‌ها  $y_i$ ، نشان دهنده مقادیر واقعی و  $x_i$  مقادیر پیش‌بینی شده و  $m$  نیز به عنوان تعداد مشاهدات در نظر گرفته شده است. به عبارت دیگر، درصد میانگین قدر مطلق خطا نشان دهنده میزان خطا در پیش‌بینی‌ها است.

بررسی‌ها نشان می‌دهند متغیرهای تاثیرگذار در ساخت معماری بهینه شبکه عصبی حافظه کوتاه مدت ماندگار شامل تعداد نرون‌ها، اندازه دسته و لایه دراپ اوت و بازه زمانی سرمایه‌گذار است. بنابراین برای بررسی و انتخاب بهترین معماری، شبکه عصبی حافظه کوتاه مدت ماندگار در بازه زمانی سرمایه‌گذاری بلندمدت، در دو حالت کلی (با دراپ اوت و بدون آن)، با استفاده از ترکیبات مختلف متغیرهای یادشده (هشت معماری مختلف) طراحی شد. در ذیل به بررسی و ارزیابی هر کدام از آن‌ها به تفصیل می‌پردازیم. شایان بیان است برای دستیابی به پاسخ نهایی در هر معماری، اجرای مدل طراحی شده ۲۰۰ مرتبه با هر یک از جایگشت‌های تعداد نرون و اندازه دسته تکرار شد.

1. MAPE

2. RSME



الف) معماری حافظه کوتاه مدت ماندگار بدون در نظر گرفتن لایه دراپ اوت جدول (۵) نتایج محاسبه درصد قدرمطلق میانگین خطا و مجذور میانگین مربعات خطا و همچنین تعداد نقاط موفق و ناموفق پیش‌بینی نشانک‌ها را بدون در نظر گرفتن لایه دراپ اوت برای چهار معماری مختلف نشان می‌دهد.

جدول ۵. ضریب خطا پیش‌بینی بدون لایه دراپ اوت

تعداد نرون		نوع خطا	اندازه دسته
۲۵۶	۱۲۸		
		درصد قدرمطلق میانگین خطا	۳۲
۳۹/۷۷٪	۳۹/۸۸٪	مجدور میانگین مربعات خطا	
۱۴۰	۱۴۱	تعداد موفقیت	
۲۴۸۱۰	۲۴۷۶۵	تعداد شکست	
		درصد قدرمطلق میانگین خطا	۶۴
۴۰/۰۹٪	۴۰/۰۸٪	مجدور میانگین مربعات خطا	
۱۳۳	۱۳۳	تعداد موفقیت	
۲۴۶۷۸	۲۴۶۸۲	تعداد شکست	
		تعداد شکست	
۱۶۵۱۳	۱۶۵۰۹		

منبع: یافته‌های پژوهش

همانطور که در جدول (۵) مشاهده می‌شود، تعداد کل نقاط واقعی، بدون در نظر گرفتن لایه دراپ اوت برابر با ۴۱۱۹۱ می‌باشد. همچنین نتایج نشان می‌دهند که از بین معماری‌های پیشنهادی برای سرمایه‌گذاران بلند مدت، مدل با اندازه دسته ۳۲ و تعداد نرون ۲۵۶ عملکرد بهتری داشته است. به عبارت دیگر در این ترکیب نسبت نقاط پیش‌بینی شده به نقاط واقعی بیشتر بوده و این حالت دارای کمترین میزان شکست است.

#### ب) معماری LSTM با در نظر گرفتن لایه دراپ اوت

در این معماری، LSTM را با در نظر گرفتن لایه دراپ اوت بررسی می‌کنیم. جدول (۶) نتایج چهار معماری را در این حالت نشان می‌دهد.

جدول ۶. ضریب خطا پیش‌بینی با لایه دراپ اوت

تعداد نرون		نوع خطا	اندازه دسته
۲۵۶	۱۲۸		
۳۶/۳٪	۳۶/۴۷٪	درصد قدرمطلق میانگین خطا	۳۲
۱۲۷	۱۲۸	مجدور میانگین مربعات خط	
۲۶۲۳۹	۲۶۱۶۹	تعداد موفقیت	
۱۴۹۵۲	۱۵۰۲۲	تعداد شکست	
۳۶/۲۳٪	*۳۵/۸۸٪	درصد قدرمطلق میانگین خطا	۶۴
۱۲۸	۱۲۷	مجدور میانگین مربعات خط	
۲۶۲۶۸	۲۶۴۱۲	تعداد موفقیت	
۱۴۹۲۳	۱۴۷۷۹	تعداد شکست	

منبع: یافته‌های پژوهش

همانطور که در جدول (۶) مشاهده می‌شود، تعداد کل نقاط واقعی در راهبرد بلند مدت با در نظر گرفتن لایه دراپ اوت برابر با ۴۱۱۹۱ است. همچنین نتایج نشان می‌دهند که از بین معماری‌های پیشنهادی برای سرمایه‌گذاران بلند مدت، مدل با اندازه دسته ۶۴ و تعداد نرون ۱۲۸ عملکرد بهتری داشته و نسبت نقاط پیش‌بینی شده به نقاط واقعی بیشتر بوده و دارای کمترین میزان شکست است.

### بحث و نتیجه‌گیری

- در پاسخ به پرسش اول، ابتدا با کمک الگوریتم کرم شب تاب به بهینه‌سازی متغیرهای شاخص‌ها پرداختیم، نتایج بدست آمده نشان داد که در سطح اطمینان ۹۹ درصد، عملکرد راهبرد خرید و فروش مبتنی بر شاخص‌های بهینه شده بهتر از راهبردهای خرید و فروش مبتنی بر متغیرهای انگاره و خرید و نگهداری بوده است. نتایج بدست آمده توسط الگوریتم گرگ خاکستری بهینه شده و به‌عنوان یکی از ورودی‌های شبکه عصبی حافظه کوتاه مدت ماندگار قرار گرفت تا بعد از اجرای فرایند آموزش، مدل تدوین شده مورد آزمون قرار گیرد. نتایج بدست آمده از معماری‌های متفاوت شبکه عصبی حافظه کوتاه مدت ماندگار نشان می‌دهد که مدل تدوین شده، با ضریب خطایی نزدیک به ۳۶٪ قادر به پیش‌بینی نقاط خرید، فروش و نگهداری برای یک روز معاملاتی آتی است.
- به منظور تدوین مدلی کارآمد، شبکه عصبی حافظه کوتاه مدت ماندگار را در هشت معماری متفاوت با متغیرهای اندازه دسته، تعداد نرون و لایه دراپ اوت و بدون آن

بررسی کردیم. نتایج بدست آمده نشان می‌دهد که با در نظر گرفتن لایه دراپ اوت خطای پیش‌بینی در مدل تدوین شده کاهش می‌یابد، همچنین مدل پیشنهادی با اندازه دسته ۶۴، تعداد نرون ۱۲۸ و با در نظر گرفتن لایه دراپ اوت بهترین عملکرد در بین معماری‌های متفاوت را دارد و با درصد خطای ۳۵٫۸۸٪ قادر به شناسایی نقاط ورود و خروج سهم برای یک روز معاملاتی آتی است.

### مقایسه نتایج پژوهش با پژوهش‌های پیشین

به منظور ارزیابی عملکرد بخش اول مدل یعنی بهینه‌سازی پارامترهای اندیکاتورها، نتایج بدست آمده، از این بخش را با نتایج بدست آمده از مقاله با عنوان «بهینه‌سازی پارامترهای اندیکاتورهای تحلیل تکنیکال برای داده‌های درون‌روزی با استفاده از الگوریتم الهام گرفته از پدیده‌های نوری: مطالعه موردی بورس تهران» که توسط محمدعلی رستگار و فرح آشوبی ارائه شده است، مورد مقایسه قرار دادیم. در این راستا با توجه به مقاله یادشده اندیکاتور میانگین متحرک همگرایی و اگرایی، قدرت نسبی و استوکاستیک روی چهار نماد فاذر، خزامیا، و خارزم و معادن، در دوره زمانی اول فرودین ۱۳۹۸ تا اول شهریور ۱۴۰۱ مورد بررسی قرار گرفت. نتایج حاصل از این مقایسه نشان دهنده عملکرد بهتر الگوریتم کرم شب تاب در مقایسه با مدل‌های پیشین است. که می‌تواند ناشی از انتخاب مناسب بازه‌های مناسب آموزش و آزمون در این پژوهش باشد.

همچنین نتایج پژوهش حاضر با نتایج پژوهش‌های هو و همکاران (۲۰۲۱)، بودی هارتو (۲۰۲۱) و مسکیتا و همکاران (۲۰۲۰) مبنی بر قدرت پیش‌بینی شبکه عصبی حافظه کوتاه مدت ماندگار در بازار سهام مطابقت دارد.

- بر اساس یافته‌های پژوهش می‌توان پیشنهادهای کاربردی زیر را به پژوهشگران ارائه کرد.
۱. سیستم معاملاتی هوشمندی با به کارگیری رویکرد ترکیبی تحلیل فنی با تحلیل بنیادی و براساس میزان ریسک‌پذیری سرمایه‌گذاران و یادگیری ماشین طراحی شود.
  ۲. پارامترهای تاثیرگذار بر تولید و فروش در شرکت‌های تولیدی شناسایی و ضریب میزان تاثیرگذاری (محاسبه تحلیل حساسیت) آن‌ها محاسبه شود. در نهایت با به کارگیری هوش مصنوعی، سیستم معاملاتی هوشمند، مبتنی بر تغییر متغیرهای یادشده طراحی شود.

## References

- Afshari L & S Alavi. ( 2018), An intelligent model for predicting stock trends using technical analysis methods, *Financial Research Journal*, 20(2):249-264. (In Persian)
- CM. Mesquita, R. Arantes De Oliveira, AC. MacHado Pereira, Combining an LSTM neural network with the variance ratio test for time series prediction and operation on the Brazilian stock market, in: Proc. Int. Jt. Conf. Neural Networks [Internet], 2020, Available from: <http://www.b3.com.br/pt> [cited 2021 Jun 25].
- De la Fuente, David & Garrido, Alejandro & Laviada, Jaime & Gomez, Alberto (2006). "Genetic algorithms to optimise the time to make stock market investment", Proceedings of the 8th annual conference on Genetic and evolutionary computation, ACM Press, New York, NY, USA, pp. 1857-1858.
- Do-Hyung Kwon, Ju-Bong Kim, Ju-Sung Heo, Chan-Myung Kim and YounHee Han; (2019)"Time Series Classification of Cryptocurrency Price Trend Based on a Recurrent LSTM Neural Network" *Journal Of Information Processing Systems*.
- Fernandez-Rodriguez, Fernando & Gonzalez-Martel, Christopher & Sosvilla-Rivero, Simon (2001). "Optimisation of technical rules by genetic algorithms: Evidence from the madrid stock market", *Fundacion de Estudios de Economia Aplicada*.
- G. Ding, L. Qin, Study on the prediction of stock price based on the associated network model of LSTM, *Int. J. Mach. Learn. Cybern.* 11 (6) (2019) 1307–1317, Available from: <https://link.springer.com/article/10.1007/s13042-019-01041-1> [cited 2021 Aug 27] 2019 116 [Internet]. Springer.
- L. Lin & L. Cao & J. Wang & C. Zhang (2004), "The applications of genetic algorithms in stock market data mining optimisation", in: A. Zanasi, N. Ebecken, C. Brebbia (eds.), *Data Mining V: Data Mining, Text Mining and their Business Applications (DATA MINING 2004)*, WIT Press, Southampton, Boston, pp. 448.
- Lo AW, MacKinlay AC. Data-snooping biases in tests of financial asset pricing models. *The Review of Financial Studies*. 1990 Jul 1;3(3):431-67
- Marco Santos, I tried using deep learning to predict the stock market | towards data science [internet], 2020, Available from: <https://towardsdatascience.com/using-deep-learning-ai-to-predict-the-stock-market-9399cf15a312> [cited 2021 Jun 25].
- Miralavi H & Z Porzamani(2023), Providing a model based on the financial behavior of investors in order to predict stock prices using ultra-innovative methods of neural networks,12(47):76-109. (In Persian)
- N. Baba, T. Kawachi, T. Nomura, Y. Sakatani, (2004), "Utilization of NNs & Gas for improving the traditional technical analysis in the financial market", *SICE annual Conference*, 2(2), 1409-1412.
- Porzaker S & H Ebrahimpor, Optimizing cash demand prediction of ATMs in the country's banking network using deep recurrent neural network, *Journal of Operational Research in Its Applications*, 16(3):69-88. (In Persian)

- Saedi K & S Mohebi(2022), Stock portfolio optimization by comparing different technical patterns, *Financial Engineering and Portfolio Management*,49:104-125. (In Persian)
- Sezer, O. B., & Ozbayoglu, A. M. (2019). Financial trading model with stock bar chart image time series with deep convolutional neural networks. *Intelligent Automation and Soft Computing journal*
- Skabar, Andrew & Cloete, Ian (2002). "Neural networks, financial trading and the efficient markets hypothesis", Proceedings of the twenty-fifth Australasian conference on Computer science, Australian Computer Society, Inc., Darlinghurst, Australia, VOL. 4, pp. 241–249
- Sohrabi M & M Mirbargkar(2021), Modeling the Prediction of Stock Market Jumps Based on the Recurrent Neural Network and Deep Learning,15(59):245-268. (In Persian)
- Tanaka-Yamawaki M, Tokuoka S. Adaptive use of technical indicators for the prediction of intra-day stock prices. *Physica A: Statistical Mechanics and its Applications*. 2007 Sep 1; 383 (1):125-33.
- Teixeira, Lamartin Almeida & de Oliveira, Adriano Lorena Inacio (2010). "A method for automatic stock trading combining technical analysis and nearest neighbor classification", *Journal of Expert Systems with Applications*, VOL. 37, NO. 10, pp. 6885–6890.
- Thomaidis, N; (2007), "Efficient Statistical Analysis of Financial Time-Series using Neural Networks and GARCH models", PP: 2-6
- Y. Hao, Q. Gao, Predicting the trend of stock market index using the hybrid neural network based on multiple time scale feature learning, *Appl. Sci.* 10 (11) (2020).